

UNIVERSIDADE ESTADUAL DE PONTA GROSSA
SETOR DE CIÊNCIAS SOCIAIS APLICADAS
DEPARTAMENTO DE ECONOMIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA

ABRAHÃO SCHEIFER

PREVISÃO DA INFLAÇÃO NO BRASIL: DOIS ENSAIOS À LUZ DA ECONOMETRIA
CLÁSSICA E TÉCNICAS DE *MACHINE LEARNING* (2000–2025)

PONTA GROSSA

2026

ABRAHÃO SCHEIFER

PREVISÃO DA INFLAÇÃO NO BRASIL: DOIS ENSAIOS À LUZ DA ECONOMETRIA
CLÁSSICA E TÉCNICAS DE *MACHINE LEARNING* (2000–2025)

Dissertação apresentada como requisito parcial à obtenção do título de Mestre em Economia, no Programa de Pós-Graduação em Economia, Setor de Ciências Sociais Aplicadas da Universidade Estadual de Ponta Grossa.

Orientadora: Prof.^a Dr.^a Luma de Oliveira.

PONTA GROSSA

2026

S319 Scheifer, Abrahão

 Previsão da inflação no Brasil dois ensaios à luz da econometria clássica e técnicas de machine learning (2000–2025) / Abrahão Scheifer. Ponta Grossa, 2026.

 112 f.

 Dissertação (Mestrado em Economia - Área de Concentração: Economia), Universidade Estadual de Ponta Grossa.

 Orientadora: Profa. Dra. Luma de Oliveira.

 1. Inflação. 2. Previsão. 3. Séries temporais. 4. Aprendizado de máquina. 5. Curva de Phillips Novo-Keynesiana. I. Oliveira, Luma de. II. Universidade Estadual de Ponta Grossa. Economia. III.T.

CDD: 332.41

TERMO

ABRAHÃO SCHEIFER

PREVISÃO DA INFLAÇÃO NO BRASIL: DOIS ENSAIOS À LUZ DA ECONOMETRIA CLÁSSICA E TÉCNICAS DE MACHINE LEARNING (2000–2025)

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre no Programa de Pós-Graduação em Economia, da Universidade Estadual de Ponta Grossa, pela seguinte banca examinadora:

Ponta Grossa, 26 de maio de 2026

Documento assinado digitalmente
 **LUMA DE OLIVEIRA**
Data: 01/06/2026 14:37:07-0300
Verifique em <https://validar.iti.gov.br>

Prof.^a Dra Luma de Oliveira - UEPG

Documento assinado digitalmente
 **ALEX SANDER SOUZA DO CARMO**
Data: 01/06/2026 14:23:12-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Alex Sander Souza do Carmo - UEPG

Documento assinado digitalmente
 **WELLINGTON RODRIGO MONTEIRO**
Data: 29/05/2026 12:46:03-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Wellington Rodrigo Monteiro - PUCPR

Dedico este trabalho à minha mãe, que
hoje mora no céu, mas cuja presença,
amor e ensinamentos seguem guiando
minha caminhada.

AGRADECIMENTOS

A Deus, pela dádiva da vida, força e sabedoria concedidas para enfrentar os desafios desta caminhada.

À minha família, pelo apoio e incentivo constantes ao longo desta trajetória, em especial ao meu filho, Liam Eduardo Scheifer, pelo carinho, amor e, sobretudo, pela compreensão nos momentos em que o papai precisou estar ausente.

À minha querida amiga, professora e orientadora, Dra. Luma de Oliveira, pelas valiosas orientações, paciência e direcionamentos que foram fundamentais para a realização deste trabalho.

Aos estimados professores que compuseram a minha banca de defesa, Prof. Dr. Alex Sander Souza do Carmo e Prof. Dr. Wellington Rodrigo Monteiro, pela disponibilidade, leitura atenta e contribuições relevantes que enriqueceram este estudo.

Aos professores do Departamento de Economia da Universidade Estadual de Ponta Grossa, cujos conhecimentos transmitidos foram essenciais para minha formação acadêmica e profissional.

Ao Programa de Pós-Graduação em Economia da UEPG e a todos os professores e profissionais, pelo suporte institucional e dedicação que possibilitaram minha chegada até aqui.

À Universidade Estadual de Ponta Grossa e a todos os profissionais que, de alguma forma, contribuíram para a realização deste sonho, meu sincero agradecimento.

À Pontifícia Universidade Católica do Paraná (PUCPR) e à Universidade Tecnológica Federal do Paraná (UTFPR), pelos conhecimentos adquiridos ao longo de minha formação, os quais contribuíram significativamente para o desenvolvimento desta pesquisa.

Por fim, um agradecimento muito especial aos meus pais, Anair Scheifer e Davi Scheifer, que sempre acreditaram em mim e lutaram de todas as formas para que este momento se tornasse realidade. Esta conquista também pertence a vocês.

RESUMO

Esta dissertação investiga a previsão da inflação brasileira no período de 2000 a 2025, contemplando estimação histórica e projeções fora da amostra, por meio de dois ensaios complementares que articulam, de forma integrada, a tradição da econometria de séries temporais, os avanços recentes em aprendizado de máquina e um arcabouço macroeconômico disciplinador. No Ensaio 1, realiza-se uma análise comparativa entre abordagens univariadas — ARIMA, *Prophet* e *LightGBM* — utilizando dados mensais do IPCA de janeiro de 2000 a novembro de 2024, com projeções para o período de dezembro de 2024 a novembro de 2025. O desempenho preditivo é avaliado com base em métricas estatísticas consagradas na literatura (MAE, RMSE e SMAPE), complementadas por diagnóstico de resíduos e inspeção gráfica, permitindo analisar como cada método responde a padrões sazonais, mudanças de tendência e episódios de elevada volatilidade, como crises econômicas e choques exógenos. Os resultados evidenciam a capacidade do *LightGBM* de capturar não linearidades e reduzir erros médios de previsão, enquanto o ARIMA apresenta desempenho consistente em contextos mais estáveis e o *Prophet* se destaca pela decomposição interpretável de tendência e sazonalidade, sendo particularmente útil em rotinas de atualização recorrente de previsões. No Ensaio 2, avança-se de uma perspectiva estritamente univariada para uma modelagem multivariada orientada pela Curva de Phillips Novo-Keynesiana Híbrida (CPNK-H), na qual são incorporadas como variáveis explicativas a inflação defasada, as expectativas de inflação extraídas da Pesquisa Focus e o hiato do produto, estimado a partir do Índice de Atividade Econômica do Banco Central (IBC-Br) por meio do filtro de Hodrick–Prescott em modo tempo real (*one-sided*). Utilizando dados mensais de janeiro de 2004 a novembro de 2024 e projeções realizadas para o período de dezembro de 2024 a novembro de 2025, estima-se um modelo de aprendizado de máquina *LightGBM* com validação temporal, controle de complexidade e otimização de hiperparâmetros. A interpretação econômica das previsões é conduzida por meio da técnica de explicabilidade SHAP, permitindo confrontar os padrões de atribuição preditiva aprendidos pelo algoritmo com os mecanismos teóricos da literatura macroeconômica. Os achados indicam desempenho preditivo consistente no horizonte fora da amostra, bem como relevância predominante das expectativas de inflação e da inércia inflacionária, com contribuição complementar do hiato do produto na previsão da inflação brasileira, em consonância com evidências empíricas aplicadas ao país. Em conjunto, os resultados demonstram que métodos de aprendizado de máquina, quando ancorados em fundamentos macroeconômicos consistentes e acompanhados de técnicas de interpretabilidade analítica, podem complementar de forma robusta as abordagens econométricas tradicionais, ampliando simultaneamente a capacidade preditiva e o conteúdo analítico das projeções inflacionárias.

Palavras-chave: inflação; previsão; séries temporais; aprendizado de máquina; Curva de Phillips Novo-Keynesiana.

ABSTRACT

This dissertation investigates the forecasting of Brazilian inflation over the period from 2000 to 2025, encompassing historical estimation and out-of-sample projections through two complementary essays that integrate the tradition of time-series econometrics, recent advances in machine learning, and a disciplining macroeconomic framework. In Essay 1, a comparative analysis is conducted among univariate approaches — ARIMA, Prophet, and LightGBM — using monthly IPCA data from January 2000 to November 2024, with forecasts generated for the period from December 2024 to November 2025. Predictive performance is assessed using statistical error metrics widely adopted in the literature (MAE, RMSE, and SMAPE), complemented by residual diagnostics and graphical inspection, allowing an evaluation of how each method responds to seasonal patterns, trend changes, and episodes of heightened volatility, such as economic crises and exogenous shocks. The results highlight LightGBM's ability to capture nonlinearities and reduce average forecast errors, while ARIMA exhibits consistent performance in more stable environments, and Prophet stands out for its interpretable decomposition of trend and seasonality, being particularly useful in settings that require recurrent forecast updates. In Essay 2, the analysis moves beyond a purely univariate perspective toward a theory-driven multivariate modeling framework based on the Hybrid New Keynesian Phillips Curve (HNKPC). The explanatory variables include lagged inflation, inflation expectations obtained from the Focus Survey, and the output gap, constructed from the IBC-Br using a real time (one-sided) Hodrick–Prescott filter. Using monthly data from January 2004 to November 2024 and generating forecasts for the period from December 2024 to November 2025, a LightGBM model is estimated with temporal validation, complexity control, and hyperparameter optimization. The economic interpretation of the forecasts is conducted through the SHAP explainability technique, enabling a direct comparison between the predictive attribution patterns learned by the algorithm and the theoretical mechanisms emphasized in the macroeconomic literature. The findings indicate consistent predictive performance in the out-of-sample horizon, with a predominant role for inflation expectations and inflation inertia, alongside a complementary contribution from the output gap in forecasting Brazilian inflation, in line with empirical evidence for the country. Overall, the results demonstrate that machine learning methods, when grounded in consistent macroeconomic fundamentals and accompanied by interpretability techniques, can robustly complement traditional econometric approaches, simultaneously enhancing the predictive accuracy and analytical content of inflation forecasts.

Keywords: inflation; forecasting; time series; machine learning; New Keynesian Phillips Curve.

LISTA DE ILUSTRAÇÕES

Figura 2.1 – Evolução da inflação mensal medida pelo IPCA no Brasil, 2000–2024.	32
Figura 2.2 – Funções de autocorrelação (ACF) e de autocorrelação parcial (PACF) da inflação mensal brasileira (2000–2024).	36
Figura 2.3 – Ajuste amostral e previsão da inflação mensal no Brasil pelo modelo ARIMA(1,0,0) no período de 2000 a 2025.	39
Figura 2.4 – Decomposição dos componentes temporais estimados pelo modelo <i>Prophet</i> para a inflação mensal no Brasil (2000–2024).	41
Figura 2.5 – Ajuste amostral e previsão da inflação mensal no Brasil pelo modelo <i>Prophet</i> no período de 2000 a 2025.	43
Figura 2.6 – Ajuste amostral e previsão da inflação mensal no Brasil pelo modelo <i>LightGBM</i> no período de 2000 a 2025.	47
Quadro 3.1 – Descrição das variáveis, fontes de dados e período de análise utilizado no estudo (2004–2025).	75
Figura 3.1 – Ajuste amostral e previsão da inflação no Brasil pelo modelo <i>LightGBM</i> no período de 2004 a 2025.	84
Figura 3.2 – Inflação observada e prevista pelo modelo <i>LightGBM</i> no período fora da amostra (dez. 2024–nov. 2025).	85
Figura 3.3 – Distribuição dos valores SHAP das variáveis explicativas do modelo <i>LightGBM</i> aplicado à previsão da inflação mensal brasileira (2004–2025).	88
Figura A.1 – Comparação entre a inflação observada e as previsões fora da amostra dos modelos ARIMA(1,0,0), <i>Prophet</i> e <i>LightGBM</i> (dez. 2024–nov. 2025).	104
Figura B.1 – Evolução temporal das séries do modelo do segundo ensaio (2004–2024).	110

LISTA DE TABELAS

Tabela 2.1 – Estatísticas descritivas da série mensal de inflação no Brasil (2000–2024).....	33
Tabela 2.2 – Teste de raiz unitária Phillips–Perron aplicado à série mensal de inflação no Brasil (2000–2024).....	34
Tabela 2.3 – Seleção de modelos ARIMA com base nos critérios de informação AIC e BIC (2000–2024).	37
Tabela 2.4 – Resultados da estimação do modelo ARIMA(1,0,0) para a inflação mensal brasileira (2000–2024).	38
Tabela 2.5 – Desempenho preditivo do modelo ARIMA(1,0,0) para a inflação mensal no Brasil (2000–2024).....	40
Tabela 2.6 – Teste de Ljung–Box para autocorrelação dos resíduos do modelo <i>Prophet</i>	44
Tabela 2.7 – Métricas de desempenho preditivo do modelo <i>Prophet</i> para a inflação mensal no Brasil (2000–2024).....	44
Tabela 2.8 – Desempenho preditivo do modelo <i>LightGBM</i> na previsão da inflação mensal no Brasil (2000–2024).....	46
Tabela 2.9 – Teste de Ljung–Box para autocorrelação dos resíduos do modelo <i>LightGBM</i> (2000–2024).	48
Tabela 2.10 – Desempenho preditivo e comparação estrutural dos modelos ARIMA, <i>Prophet</i> e <i>LightGBM</i> na previsão da inflação no Brasil (2000–2025).....	50
Tabela 3.1 – Desempenho preditivo do modelo <i>LightGBM</i> na previsão da inflação mensal brasileira (2004–2025).....	82
Tabela 3.2 – Importância global das variáveis explicativas do modelo <i>LightGBM</i> na previsão da inflação mensal brasileira, segundo valores SHAP médios absolutos.	87
Tabela A.1 – Desempenho fora da amostra dos modelos na previsão da inflação brasileira (dez. 2024–nov. 2025).....	105
Tabela A.2 – Teste de Diebold–Mariano (DM) para comparação da acurácia preditiva fora da amostra dos modelos (dez. 2024–nov. 2025).	106
Tabela B.1 – Estatísticas descritivas das séries do modelo do segundo ensaio (2004–2024)....	108
Tabela B.2 – Teste de raiz unitária de Phillips–Perron para as séries temporais do segundo ensaio (2004–2024).	112

SUMÁRIO

1 INTRODUÇÃO.....	11
2 PREVISÃO DA INFLAÇÃO NO BRASIL: UMA ANÁLISE COMPARATIVA ENTRE O MODELO ARIMA E TÉCNICAS DE <i>MACHINE LEARNING</i> NO PERÍODO DE 2000 A 2025	15
2.1 INTRODUÇÃO	16
2.2 REVISÃO DA LITERATURA	19
2.3 METODOLOGIA.....	21
2.3.1 Modelo ARIMA.....	23
2.3.2 Modelo <i>Prophet</i>	24
2.3.3 Modelo <i>LightGBM</i>	27
2.4 AVALIAÇÃO DE DESEMPENHO DOS MODELOS	29
2.4.1 Erro médio absoluto (MAE)	30
2.4.2 Raiz do erro quadrático médio (RMSE)	30
2.4.3 Erro percentual absoluto médio simétrico (SMAPE)	31
2.5 RESULTADOS E DISCUSSÃO.....	31
2.5.1 Análise exploratória da série histórica da inflação (2000–2024)	32
2.5.2 Avaliação empírica dos modelos	35
2.5.3 Modelo ARIMA: ajuste, diagnóstico e projeções.....	35
2.5.4 Modelo <i>Prophet</i> : decomposição estrutural e desempenho preditivo.....	40
2.5.5 Modelo <i>LightGBM</i> : avaliação de desempenho e robustez preditiva	45
2.6 COMPARAÇÃO DO DESEMPENHO PREDITIVO DOS MODELOS	48
2.7 CONSIDERAÇÕES FINAIS	51
REFERÊNCIAS	54
3 PREVISÃO DA INFLAÇÃO NO BRASIL À LUZ DA CURVA DE PHILLIPS NOVO-KEYNESIANA: UMA ANÁLISE MULTIVARIADA UTILIZANDO O MODELO DE APRENDIZADO DE MÁQUINA <i>LIGHTGBM</i> (2004–2025).....	56
3.1 INTRODUÇÃO	57
3.2 EVOLUÇÃO TEÓRICA DA CURVA DE PHILLIPS	60
3.2.1 A Curva de Phillips Original	60
3.2.2 O modelo aceleracionista: Friedman e Phelps.....	61
3.2.3 Expectativas racionais e a crítica de Lucas.....	62
3.2.4 A Curva de Phillips Novo-Keynesiana.....	64

3.2.5 A Curva de Phillips Novo-Keynesiana Híbrida.....	65
3.3 EVIDÊNCIAS EMPÍRICAS DA CURVA DE PHILLIPS NOVO-KEYNESIANA NO BRASIL	66
3.4 PROPOSTA METODOLÓGICA.....	70
3.4.1 Modelo teórico.....	70
3.4.2 Especificação empírica do modelo	72
3.4.3 Fontes de dados e construção das variáveis.....	72
3.4.4 Modelo <i>Light Gradient Boosting Machine (LightGBM)</i>	75
3.4.5 Critérios de avaliação e interpretabilidade do modelo	79
3.5 RESULTADOS E DISCUSSÃO.....	82
3.5.1 Desempenho preditivo do modelo <i>LightGBM</i>	82
3.5.2 Interpretação econômica dos resultados via SHAP	86
3.5.3 Discussão dos resultados à luz da Curva de Phillips Novo-Keynesiana Híbrida	90
3.6 CONSIDERAÇÕES FINAIS	92
REFERÊNCIAS	95
4 CONCLUSÃO.....	98
APÊNDICE A – AVALIAÇÃO PREDITIVA FORA DA AMOSTRA DOS MODELOS DO PRIMEIRO ENSAIO	103
APÊNDICE B – ANÁLISE EXPLORATÓRIA DAS SÉRIES ECONÔMICAS UTILIZADAS NO SEGUNDO ENSAIO	108

1 INTRODUÇÃO

A inflação constitui um dos fenômenos centrais da macroeconomia contemporânea, especialmente em economias emergentes, como a brasileira, nas quais a trajetória dos preços exerce influência direta sobre a política monetária, a formação de expectativas inflacionárias, o planejamento das empresas, as decisões de consumo das famílias e a preservação do poder de compra da população. Em regimes de metas de inflação, sua previsão adquire relevância ainda maior, pois representa elemento decisivo para a calibração da taxa básica de juros, para a condução da política econômica e para a coordenação das expectativas dos agentes econômicos (Banco Central do Brasil, 2024; Clarida; Galí; Gertler, 1999). Nesse contexto, compreender a dinâmica inflacionária e antecipar seu comportamento de forma consistente constitui tarefa central dos formuladores de política econômica, sendo fundamental para a condução eficiente da política monetária. Além disso, essa capacidade preditiva contribui para o fortalecimento da eficácia, da transparência e da credibilidade das políticas econômicas, ao mesmo tempo em que fornece subsídios relevantes para a tomada de decisão de agentes públicos e privados.

No caso brasileiro, esse desafio assume ainda contornos mais particulares. Historicamente, a inflação no país tem sido marcada pela coexistência de persistência inflacionária, choques de oferta, oscilações cambiais, mudanças no ambiente internacional, pressões oriundas da atividade econômica e reações da política monetária. Mesmo após a consolidação do regime de metas de inflação, iniciado em 1999, a trajetória do Índice Nacional de Preços ao Consumidor Amplo (IPCA) continuou a refletir uma combinação complexa de fatores estruturais e conjunturais, o que dificulta a obtenção de previsões consistentes e robustas ao longo do tempo (Banco Central do Brasil, 2024; Machado; Portugal, 2014).

Além disso, a presença recorrente de episódios de volatilidade — como a crise financeira internacional de 2008, os desdobramentos inflacionários do período pandêmico da COVID-19 e os efeitos de choques externos sobre cadeias produtivas e preços — evidencia que a inflação brasileira não apresenta comportamento temporal simples, linear ou plenamente regular. Trata-se, portanto, de um fenômeno cuja modelagem exige instrumentos capazes de lidar simultaneamente com persistência, sazonalidade, mudanças de regime e não linearidades, o que reforça a necessidade de abordagens metodológicas mais flexíveis e abrangentes, compatíveis com a complexidade inerente ao processo inflacionário nacional.

Tradicionalmente, a literatura de previsão econômica tem recorrido a modelos estatísticos consolidados, como os modelos autorregressivos integrados de médias móveis (ARIMA), amplamente utilizados em razão de sua simplicidade, interpretabilidade e bom

desempenho em ambientes relativamente estáveis. No âmbito das séries temporais, esses modelos constituem uma referência clássica para a identificação de padrões dinâmicos baseados na própria trajetória histórica da variável analisada (Box et al., 2016; Hamilton, 1994). No entanto, a natureza univariada desses modelos impõe restrições relevantes, especialmente quando o objetivo da análise não se limita ao desempenho preditivo, mas também à compreensão dos fatores que influenciam a dinâmica inflacionária, uma vez que sua capacidade de previsão depende fundamentalmente da persistência da própria série.

Apesar dessas limitações estruturais, tais modelos permanecem como referências importantes na previsão macroeconômica, sobretudo quando o interesse se concentra na identificação de padrões temporais presentes no histórico da variável. Contudo, a crescente complexidade dos fenômenos econômicos contemporâneos, aliada à expansão das técnicas computacionais, tem impulsionado a adoção de abordagens preditivas mais flexíveis, especialmente no campo do aprendizado de máquina (*machine learning*). Nesse contexto, essas inovações metodológicas têm ampliado de forma significativa o conjunto de ferramentas disponíveis para a previsão de séries temporais, oferecendo métodos promissores e robustos do ponto de vista preditivo (Hyndman; Athanasopoulos, 2018; Ferreira, 2023). Entre essas abordagens, destacam-se algoritmos como o *Prophet*, proposto por Taylor e Letham (2017), e o *Light Gradient Boosting Machine (LightGBM)*, desenvolvido por Ke et al. (2017), que apresentam vantagens específicas na identificação de sazonalidades, tendências, rupturas estruturais e relações não lineares.

No entanto, essa transformação metodológica não elimina a necessidade de rigor teórico para compreender, de forma mais clara e consistente, os mecanismos subjacentes aos fenômenos econômicos que afetam diretamente a dinâmica inflacionária. No âmbito das aplicações macroeconômicas, previsões mais acuradas são, sem dúvida, desejáveis, na medida em que contribuem para decisões mais informadas e para uma condução mais eficiente da política econômica. Contudo, sua utilidade analítica se amplia significativamente quando articuladas a fundamentos teóricos consistentes e amplamente discutidos na literatura. Em outras palavras, o avanço das técnicas preditivas não torna dispensável a teoria econômica; ao contrário, reforça a importância de sua integração ao desenho empírico da pesquisa, de modo que os modelos não apenas produzam projeções mais precisas, mas também permitam uma interpretação economicamente coerente dos padrões extraídos dos dados empíricos. É justamente nessa interseção entre tradição econométrica, inovação metodológica e disciplina teórica que esta dissertação se insere.

Esta pesquisa tem como tema central a previsão da inflação no Brasil no período de

2000 a 2025, propondo uma investigação desenvolvida em dois ensaios complementares. O primeiro ensaio concentra-se na comparação entre abordagens univariadas de previsão da inflação, examinando o desempenho relativo dos modelos *ARIMA*, *Prophet* e *LightGBM*. O objetivo, nesse caso, é avaliar em que medida metodologias com estruturas distintas respondem à dinâmica histórica da inflação brasileira, considerando critérios de acurácia preditiva, aderência aos dados e capacidade de lidar com padrões temporais e episódios de maior instabilidade.

Já o segundo ensaio amplia o escopo analítico ao abandonar uma perspectiva estritamente univariada e incorporar, em um modelo multivariado, variáveis centrais da literatura macroeconômica sobre inflação, com base na Curva de Phillips Novo-Keynesiana Híbrida. Nessa etapa, a inflação é analisada à luz da interação entre inércia inflacionária, expectativas de inflação e hiato do produto, em consonância com a formulação híbrida proposta por Galí e Gertler (2000) e com evidências empíricas aplicadas ao contexto brasileiro. Com base nessa estrutura analítica, o algoritmo *LightGBM* é empregado como ferramenta preditiva flexível, complementada por técnicas de interpretabilidade baseadas em valores SHAP, que permitem avaliar a contribuição relativa de cada variável no processo de previsão (Lundberg e Lee, 2017).

A articulação entre os dois ensaios confere unidade analítica à dissertação ao integrar abordagens complementares de modelagem da inflação, combinando comparação empírica e fundamentação teórica. O primeiro ensaio estabelece base comparativa relevante ao confrontar modelos de diferentes naturezas em um ambiente univariado, permitindo identificar ganhos e limitações associados à transição de abordagens clássicas para técnicas mais modernas de aprendizado de máquina. O segundo ensaio, por sua vez, desloca a análise para um terreno conceitualmente mais denso, no qual a previsão da inflação deixa de depender apenas da história da própria série e passa a ser orientada por um arcabouço macroeconômico explícito. Assim, a dissertação não se limita a verificar qual modelo prevê melhor em termos absolutos; busca também examinar em que medida a incorporação de fundamentos econômicos e de mecanismos de interpretabilidade pode enriquecer o conteúdo analítico das previsões inflacionárias.

A relevância do estudo pode ser compreendida sob, ao menos, três dimensões. Em primeiro lugar, há uma contribuição metodológica, na medida em que a dissertação compara e integra abordagens econométricas e algoritmos de aprendizado de máquina aplicados a um problema central da macroeconomia brasileira. Em segundo lugar, há uma contribuição analítica, pois o trabalho procura aproximar desempenho preditivo e coerência teórica, especialmente ao utilizar a Curva de Phillips Novo-Keynesiana Híbrida como referência para a

especificação multivariada do segundo ensaio. Em terceiro lugar, há uma contribuição prática, uma vez que previsões mais robustas e melhor interpretadas podem oferecer subsídios relevantes à formulação da política monetária, ao planejamento empresarial e à avaliação de cenários macroeconômicos em ambientes marcados por elevada incerteza.

Os resultados gerais da dissertação apontam, por um lado, para o potencial do *LightGBM* na captura de não linearidades e na redução dos erros médios de previsão, especialmente quando comparado a abordagens tradicionais em contextos mais complexos; por outro, indicam que modelos mais interpretáveis, como o ARIMA e o *Prophet*, preservam utilidade analítica em situações específicas, seja pela simplicidade estrutural, seja pela decomposição explícita de tendência e sazonalidade. No ensaio multivariado, os achados sugerem papel predominante das expectativas de inflação e da inércia inflacionária, com contribuição complementar do hiato do produto para a dinâmica dos preços, resultado compatível com a evidência empírica observada para o Brasil e com a interpretação de que a inflação brasileira reflete a interação entre componentes retrospectivos e prospectivos em sua determinação. Em conjunto, essas evidências reforçam a tese de que métodos de aprendizado de máquina, quando ancorados em fundamentos macroeconômicos consistentes e acompanhados de instrumentos de interpretabilidade, podem complementar de forma robusta as abordagens econométricas tradicionais no campo da previsão econômica.

Além desta introdução, a dissertação está organizada em dois ensaios autônomos, porém analiticamente conectados, seguidos de apêndices que aprofundam a avaliação fora da amostra e a análise exploratória das séries utilizadas. Essa estrutura permite ao leitor acompanhar, em sequência lógica, o percurso que vai da comparação entre modelos univariados à construção de uma estratégia preditiva multivariada disciplinada pela teoria econômica. Desse modo, o trabalho busca contribuir para o debate contemporâneo sobre previsão da inflação ao evidenciar que o avanço metodológico mais promissor não reside na substituição pura e simples dos modelos clássicos, mas na construção de uma integração consistente entre tradição econométrica, flexibilidade algorítmica e coerência econômica.

2 PREVISÃO DA INFLAÇÃO NO BRASIL: UMA ANÁLISE COMPARATIVA ENTRE O MODELO ARIMA E TÉCNICAS DE MACHINE LEARNING NO PERÍODO DE 2000 A 2025

Resumo: Este estudo compara o desempenho dos modelos ARIMA(1,0,0), *Prophet* e *LightGBM* na previsão da inflação brasileira, medida pelo Índice Nacional de Preços ao Consumidor Amplo (IPCA), utilizando dados mensais de janeiro de 2000 a novembro de 2024, com projeções realizadas para o período de dezembro de 2024 a novembro de 2025. A avaliação dos modelos foi conduzida por meio de métricas estatísticas consolidadas na literatura — Erro Médio Absoluto (MAE), Raiz do Erro Quadrático Médio (RMSE) e Erro Percentual Absoluto Médio Simétrico (SMAPE) —, complementadas por análises gráficas e diagnósticos dos resíduos. Os resultados indicam a superioridade preditiva do *LightGBM*, que apresentou os menores erros de predição e maior capacidade de capturar padrões não lineares e choques exógenos. O ARIMA(1,0,0) demonstrou desempenho consistente em contextos mais estáveis, sendo recomendado para aplicações com menor complexidade estrutural. O *Prophet*, embora menos preciso nas métricas quantitativas, destacou-se pela flexibilidade na decomposição de componentes sazonais e de tendência, sendo útil em cenários que demandam previsões recorrentes e interpretabilidade. Conclui-se que a escolha do modelo deve considerar o contexto econômico e os objetivos analíticos da previsão, recomendando-se o uso de abordagens híbridas e técnicas avançadas para aprimorar a acurácia das projeções inflacionárias.

Palavras-chave: ARIMA; *LightGBM*; previsão de inflação; *Prophet*; séries temporais.

Abstract: This study compares the performance of the ARIMA(1,0,0), Prophet, and LightGBM models in forecasting Brazilian inflation, measured by the Broad National Consumer Price Index (IPCA), using monthly data from January 2000 to November 2024, with projections for the period from December 2024 to November 2025. The models were evaluated using statistical metrics widely established in the literature — Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), and Symmetric Mean Absolute Percentage Error (SMAPE) — complemented by graphical analyses and residual diagnostics. The results indicate the superior predictive performance of the LightGBM model, which achieved the lowest forecast errors and showed greater ability to capture nonlinear patterns and exogenous shocks. The ARIMA(1,0,0) model demonstrated consistent performance in more stable contexts and is recommended for applications with lower structural complexity. Although less accurate in quantitative metrics, the Prophet model stood out for its flexibility in decomposing seasonal and trend components, proving useful in scenarios requiring recurring forecast updates and greater interpretability. The study concludes that model selection should consider the economic context and the analytical objectives of forecasting, recommending the adoption of hybrid approaches and advanced techniques to improve the accuracy of inflation projections.

Keywords: ARIMA; LightGBM; inflation forecasting; Prophet; time series.

Classificação JEL: C53, E31, C22.

2.1 INTRODUÇÃO

A previsão da inflação desempenha papel fundamental na formulação de políticas públicas e no planejamento estratégico de governos, empresas e famílias. Ao antecipar o comportamento dos preços na economia, essas projeções subsidiam decisões econômicas fundamentais, como a definição da taxa básica de juros, a condução das políticas fiscal e monetária e a gestão de contratos, investimentos e orçamentos. Dessa forma, ao reduzir a incerteza associada ao ambiente macroeconômico, a previsão inflacionária contribui para maior estabilidade decisória dos agentes públicos e privados e fornece suporte informacional relevante aos tomadores de decisão.

Tradicionalmente, modelos econométricos como o *ARIMA (AutoRegressive Integrated Moving Average)* têm sido amplamente utilizados na previsão de séries temporais, em razão de sua estrutura parcimoniosa e de sua consistência na modelagem de processos estocásticos caracterizados por dependências lineares ao longo do tempo. No âmbito da abordagem Box-Jenkins, tais modelos permitem descrever a dinâmica temporal por meio de componentes autorregressivos e de médias móveis, bem como de transformações destinadas a garantir propriedades de estacionariedade, elemento essencial para a inferência estatística e para a previsão em séries temporais (Box et al., 2016; Hamilton, 1994).

Entretanto, a crescente complexidade das economias contemporâneas, marcada pela recorrência de choques estruturais, mudanças de regime e interações não lineares, impõe limitações relevantes a modelos estritamente lineares. Em particular, a presença de quebras estruturais, heterogeneidade temporal e múltiplas sazonalidades pode comprometer a capacidade desses modelos de capturar adequadamente a dinâmica subjacente de variáveis macroeconômicas, como a inflação.

Diante dessas limitações, os avanços recentes em técnicas de aprendizado de máquina têm ampliado o conjunto de ferramentas disponíveis para modelagem preditiva, ao disponibilizar métodos mais flexíveis e capazes de capturar relações não lineares e interações complexas. Entre essas abordagens, destaca-se o *Prophet*, desenvolvido por Taylor e Letham (2017), que utiliza uma estrutura aditiva baseada na decomposição de componentes temporais, como tendência, sazonalidade e efeitos de eventos específicos. Outro modelo relevante é o *Light Gradient Boosting Machine (LightGBM)*, proposto por Ke et al. (2017), algoritmo baseado em árvores de decisão que se destaca pela eficiência computacional e pela capacidade de identificar padrões não lineares em grandes volumes de dados.

No contexto brasileiro, a dinâmica inflacionária apresenta características específicas que

tornam sua previsão particularmente desafiadora. Desde a implementação do Plano Real, em 1994, o Índice Nacional de Preços ao Consumidor Amplo (IPCA), calculado pelo Instituto Brasileiro de Geografia e Estatística (IBGE), consolidou-se como o principal indicador oficial da inflação brasileira, servindo como referência para o regime de metas inflacionárias conduzido pelo Banco Central do Brasil (Banco Central do Brasil, 2024). Além disso, ao orientar a política monetária, especialmente por meio da definição da taxa básica de juros (Selic), o índice também desempenha papel relevante na indexação de contratos e reajustes salariais, o que reforça sua importância prática no cenário econômico nacional.

A importância da previsão inflacionária decorre, sobretudo, da complexidade de sua trajetória, frequentemente influenciada por fatores internos e externos, como oscilações cambiais, choques de oferta, variações nos preços internacionais e mudanças na demanda agregada, além da presença de padrões sazonais relevantes, fatores que ampliam a dificuldade de antecipar com precisão o comportamento futuro dos preços. Diante desse cenário, torna-se evidente a necessidade de metodologias preditivas mais robustas, capazes de capturar tais especificidades de forma mais abrangente e precisa.

Em resposta a esse desafio, este estudo propõe uma análise comparativa entre três metodologias — ARIMA, *Prophet* e *LightGBM* — aplicadas à previsão da inflação brasileira, medida pelo IPCA. Para isso, utilizam-se dados mensais referentes ao período de janeiro de 2000 a novembro de 2024, contemplando as etapas de ajuste, validação e previsão. Adicionalmente, são geradas projeções para o intervalo de dezembro de 2024 a novembro de 2025, permitindo avaliar a robustez dos modelos em um horizonte futuro não realizado.

Para mensurar o desempenho preditivo das metodologias selecionadas, a avaliação dos modelos baseia-se em métricas estatísticas consolidadas na literatura, como o Erro Médio Absoluto (MAE), a Raiz do Erro Quadrático Médio (RMSE) e o Erro Percentual Absoluto Simétrico (SMAPE), complementadas por análises gráficas que possibilitam verificar a aderência das estimativas aos dados históricos e a adequação de cada modelo à dinâmica inflacionária observada (Hyndman; Koehler, 2006).

A definição das metodologias comparadas, por sua vez, decorreu de uma estratégia orientada pela literatura de previsão de séries temporais, buscando contemplar, de forma criteriosa, diferentes classes de métodos amplamente empregadas em aplicações macroeconômicas. Nesse sentido, o modelo ARIMA foi selecionado por sua ampla consolidação na literatura de previsões e por seu desempenho historicamente consistente em séries com maior estabilidade temporal. Por sua vez, os modelos *Prophet* e *LightGBM* foram incluídos com base em evidências recentes da literatura especializada, sobretudo em razão de

sua maior flexibilidade para capturar padrões não lineares, sazonalidades e possíveis mudanças estruturais, características frequentemente associadas à dinâmica inflacionária brasileira. Dessa forma, a seleção desses modelos permite comparar técnicas tradicionais e métodos baseados em aprendizado de máquina em uma estrutura empírica aderente às especificidades do fenômeno analisado.

À luz desses elementos, a relevância deste estudo assenta-se em três pilares fundamentais. Do ponto de vista acadêmico, contribui para o debate acerca da transição entre métodos econométricos clássicos e técnicas modernas de aprendizado de máquina aplicadas à modelagem econômica. Sob a perspectiva metodológica, o trabalho avança ao incorporar ferramentas analíticas mais robustas e flexíveis, capazes de capturar padrões mais complexos em séries temporais, ampliando o escopo da modelagem preditiva. No campo prático, o aprimoramento das previsões inflacionárias fornece subsídios valiosos para a formulação de políticas monetárias mais eficazes, além de apoiar decisões empresariais mais bem informadas e contribuir para a preservação do poder de compra da população — especialmente das camadas de baixa renda —, promovendo maior equidade econômica e auxiliando na mitigação das desigualdades sociais.

Assim, esta pesquisa busca não apenas contribuir para o avanço da literatura acadêmica, mas também oferecer uma abordagem teórica e aplicada sobre o tema, por meio da comparação entre técnicas tradicionais e modernas de previsão da inflação. Espera-se que os resultados obtidos possam fornecer orientações consistentes para pesquisadores e profissionais interessados em aprimorar a previsão econômica por meio da escolha de modelos mais eficazes, além de estimular novas investigações no campo da análise de séries temporais.

Com base nessa proposta, o artigo está estruturado, além desta introdução, em seis seções. A Seção 2.2 apresenta a revisão da literatura, abordando os principais conceitos e métodos de previsão de séries temporais. A Seção 2.3 detalha a metodologia adotada, incluindo as fontes de dados, os critérios de modelagem e as métricas de avaliação. A Seção 2.4 apresenta os procedimentos de avaliação de desempenho dos modelos. A Seção 2.5 reúne os resultados e a discussão. A Seção 2.6 apresenta a comparação do desempenho preditivo entre as metodologias analisadas. Por fim, a Seção 2.7 expõe as considerações finais do estudo, bem como suas limitações e sugestões para pesquisas futuras. Ao final da dissertação, o Apêndice A apresenta análises complementares ao primeiro ensaio, por meio de uma avaliação adicional do desempenho preditivo fora da amostra dos modelos ARIMA, *Prophet* e *LightGBM*.

2.2 REVISÃO DA LITERATURA

A previsão de séries temporais constitui um campo amplamente investigado nas áreas de economia e ciência de dados, com aplicações que abrangem desde a projeção de indicadores macroeconômicos até a precificação de ativos financeiros. Nas últimas décadas, esse campo evoluiu significativamente, impulsionado tanto pelo avanço das técnicas econométricas quanto pelo desenvolvimento de métodos baseados em aprendizado de máquina, os quais ampliaram as possibilidades analíticas e contribuíram para a melhoria da acurácia preditiva em diferentes contextos econômicos (Hyndman; Athanasopoulos, 2018; Hasan et al., 2022).

Entre as aplicações mais relevantes desse campo, destaca-se a previsão da inflação, variável central para a condução da política monetária, especialmente em economias emergentes. No caso brasileiro, caracterizado por recorrentes choques externos, elevada volatilidade cambial e episódios de instabilidade fiscal, a construção de projeções confiáveis assume papel estratégico na definição da taxa básica de juros (Selic) e na formação das expectativas dos agentes econômicos. Esse aspecto é particularmente relevante no contexto do regime de metas de inflação, adotado no país desde 1999, o qual exige sinalizações consistentes por parte da autoridade monetária e gestão eficaz das expectativas inflacionárias.

Nesse cenário, a escolha de modelos adequados para a previsão da inflação torna-se fundamental, uma vez que a qualidade das projeções influencia diretamente decisões de política econômica, investimentos privados e o próprio bem-estar da população. Assim, a busca por metodologias que conciliem rigor estatístico, capacidade adaptativa e sensibilidade a padrões econômicos complexos torna-se cada vez mais relevante, especialmente em ambientes caracterizados por elevada volatilidade e pela ocorrência de choques exógenos que afetam a dinâmica inflacionária.

No âmbito dos métodos clássicos, o modelo *ARIMA* (*AutoRegressive Integrated Moving Average*) destaca-se historicamente por sua estrutura relativamente simples e por sua eficiência na modelagem de séries temporais. Desenvolvido a partir da metodologia Box-Jenkins, esse modelo representa a dinâmica da série por meio da combinação de componentes autorregressivos (AR), de médias móveis (MA) e de diferenciação (I), permitindo a remoção de tendências e a estabilização da série sob a hipótese de estacionariedade (Box et al., 2016; Hamilton, 1994). Essas características tornam o modelo particularmente eficaz em previsões de curto prazo, desde que a série apresente comportamento linear e relativa estabilidade ao longo do tempo. No entanto, suas limitações tornam-se evidentes diante de estruturas não estacionárias, múltiplos regimes sazonais e dinâmicas não lineares, fatores frequentemente

observados em séries macroeconômicas, como a inflação brasileira.

Apesar de sua ampla utilização, os modelos ARIMA apresentam limitações quando aplicados a séries caracterizadas por não linearidades, mudanças estruturais ou padrões sazonais complexos. Em particular, a presença de quebras estruturais e de dinâmicas não estacionárias pode reduzir o desempenho preditivo desses modelos, evidenciando a necessidade de abordagens alternativas mais flexíveis, especialmente em contextos macroeconômicos como o da inflação.

Diante dessas limitações, abordagens baseadas em aprendizado de máquina têm ganhado espaço na literatura aplicada, oferecendo alternativas mais flexíveis e adaptáveis. Entre elas, destaca-se o modelo *Prophet*, desenvolvido por Taylor e Letham (2017), cuja principal vantagem reside na decomposição aditiva da série temporal em componentes de tendência, sazonalidade e eventos pontuais, permitindo ajustes automáticos mesmo em contextos de descontinuidade estrutural. Segundo Borges (2024), essa característica torna o modelo especialmente apropriado para séries com alta variabilidade, como a inflação brasileira.

Outro modelo promissor na modelagem de séries temporais é o *Light Gradient Boosting Machine (LightGBM)*, desenvolvido por Ke et al. (2017), que utiliza a técnica de *gradient boosting* aplicada a árvores de decisão. Sua principal vantagem reside na elevada eficiência computacional, aliada à capacidade de modelar relações não lineares complexas, característica frequentemente presente em séries econômicas.

Estudos empíricos reportam desempenho competitivo do *LightGBM* em relação a outras abordagens baseadas em árvores, tanto em termos de acurácia quanto de eficiência computacional (Ke et al., 2017). Além disso, sua capacidade de incorporar variáveis exógenas de forma eficiente amplia seu potencial preditivo. Enquanto o ARIMA permite essa extensão por meio de sua versão *ARIMAX*, o *LightGBM* possibilita a inclusão simultânea de múltiplas variáveis explicativas e a modelagem de interações não lineares, característica amplamente documentada na literatura sobre algoritmos de *gradient boosting* baseados em árvores de decisão (Ke et al., 2017). Essa flexibilidade mostra-se especialmente relevante no contexto brasileiro, em que a inflação é influenciada por fatores como política monetária, flutuações cambiais, choques de oferta e variações nos preços externos.

No contexto brasileiro, observa-se interesse crescente na aplicação de técnicas modernas ao campo da previsão econômica. Frainer (2024) demonstra que modelos de aprendizado de máquina, como *Random Forest* e *LightGBM*, tendem a superar abordagens tradicionais na previsão da inflação. Borges (2024), ao utilizar o modelo *Prophet* na estimativa de preços de criptomoedas, evidencia sua aplicabilidade em ambientes altamente voláteis, mesmo em

amostras extensas e instáveis. Complementarmente, Ferreira (2023) demonstra que o uso de técnicas de aprendizado de máquina, especialmente quando combinado com dados desagregados, pode melhorar o desempenho preditivo da inflação em relação a modelos tradicionais. Em outra aplicação comparativa, Hasan et al. (2022) mostram que, embora o modelo ARIMA apresente o melhor desempenho em termos de erro, modelos como o *LightGBM* alcançam níveis de acurácia próximos, ao mesmo tempo em que oferecem ganhos computacionais significativos, especialmente em bases de dados de grande dimensão.

Paralelamente às comparações entre métodos individuais, estudos recentes têm explorado o uso de modelos híbridos, que combinam técnicas econométricas tradicionais com algoritmos de aprendizado de máquina. Essa abordagem busca potencializar as vantagens de cada classe de modelo, sobretudo em cenários de elevada incerteza e volatilidade. Nesse sentido, Hyndman e Athanasopoulos (2018) argumentam que essa estratégia pode conferir maior robustez às previsões, especialmente em contextos marcados por choques exógenos e mudanças estruturais recorrentes na economia.

Apesar dos avanços observados, a literatura nacional ainda carece de estudos comparativos sistemáticos que avaliem o desempenho relativo de diferentes metodologias sob distintos contextos econômicos. Essa lacuna mostra-se particularmente relevante diante da demanda crescente por previsões mais robustas, capazes de subsidiar decisões de política econômica e estratégias do setor privado com maior consistência e precisão. Assim, o presente estudo busca contribuir para a literatura sobre previsão econômica ao oferecer uma análise empírica fundamentada na comparação entre abordagens tradicionais e modernas de modelagem preditiva aplicadas à inflação brasileira. Com base nessa delimitação, a seção seguinte apresenta a estratégia metodológica adotada, detalhando a base de dados, os modelos selecionados e os critérios utilizados para avaliar o desempenho preditivo das metodologias analisadas.

2.3 METODOLOGIA

Esta seção apresenta a metodologia utilizada para a comparação entre os modelos ARIMA, *Prophet* e *LightGBM* na previsão da inflação no Brasil, tendo como variável de interesse o Índice Nacional de Preços ao Consumidor Amplo (IPCA). A escolha desse indicador justifica-se por se tratar do principal índice oficial da inflação brasileira, utilizado como referência pelo Banco Central do Brasil (BCB) na condução da política monetária e no regime de metas de inflação vigente desde 1999. Além disso, sua trajetória influencia diretamente

decisões econômicas relevantes, como reajustes salariais, atualização de contratos, definição de taxas de juros, planejamento financeiro de agentes econômicos, decisões de investimento e formulação de políticas públicas, reforçando sua relevância empírica e aplicada.

Nesse contexto, a base de dados utilizada consiste em observações mensais do IPCA, extraídas por meio da API pública disponibilizada pelo Banco Central do Brasil, abrangendo o período de janeiro de 2000 a novembro de 2024. Essa janela temporal foi selecionada com o propósito de contemplar um ciclo econômico abrangente sob o regime de metas de inflação, incorporando episódios relevantes da economia brasileira, como a crise financeira global de 2008 e os impactos econômicos decorrentes da pandemia de COVID-19. A inclusão desses eventos possibilita avaliar o desempenho e a robustez dos modelos analisados em contextos de elevada volatilidade, rupturas estruturais e instabilidade macroeconômica, condições particularmente relevantes para a avaliação da capacidade preditiva das metodologias consideradas.

Considerando as propriedades da base de dados e a complexidade inerente à dinâmica inflacionária, a seleção dos modelos *ARIMA*, *Prophet* e *LightGBM* decorre de suas características distintas e complementares. O *ARIMA* representa uma metodologia clássica, amplamente consolidada na literatura econométrica e particularmente eficaz na modelagem de séries temporais estacionárias. O *Prophet*, por sua vez, caracteriza-se por sua estrutura aditiva e flexível, permitindo a decomposição explícita da série em componentes de tendência, sazonalidade e eventos pontuais. Já o *LightGBM* adota uma abordagem moderna de aprendizado de máquina baseada em *boosting* de árvores de decisão, destacando-se por sua capacidade de capturar relações não lineares e interações complexas com elevada eficiência computacional. Em conjunto, esses modelos permitem comparar abordagens tradicionais e métodos contemporâneos de previsão em uma mesma estrutura empírica.

No que se refere à implementação empírica dos modelos, utilizou-se a linguagem de programação *Python*, executada no ambiente *Google Colab*, plataforma de computação em nuvem que oferece recursos acessíveis e simplifica a execução de *scripts*. Essa escolha fundamenta-se na ampla gama de bibliotecas especializadas em estatística, modelagem preditiva e aprendizado de máquina, que possibilitam o desenvolvimento de aplicações reprodutíveis, eficientes e metodologicamente rigorosas. A integração dessas ferramentas computacionais permitiu a construção de um *pipeline* analítico robusto, abrangendo desde a aquisição e o pré-processamento dos dados até a estimação e avaliação dos modelos, assegurando replicabilidade, transparência e consistência metodológica no processo de geração dos resultados. Com base nessa estrutura, procede-se à apresentação dos modelos considerados

na análise, iniciando-se pelo modelo ARIMA, adotado como referência clássica para a modelagem da série temporal da inflação.

2.3.1 Modelo ARIMA

O modelo ARIMA, originalmente desenvolvido por Box e Jenkins (1976) e posteriormente sistematizado em versões mais recentes (Box et al., 2016), constitui uma das abordagens clássicas mais consolidadas na literatura de séries temporais. Sua principal característica reside na capacidade de representar padrões dinâmicos ao longo do tempo por meio da combinação de três componentes fundamentais: o termo autorregressivo (AR), que estabelece uma relação linear entre os valores atuais e seus valores defasados; o termo de integração (I), que indica o número de diferenciações necessárias para tornar a série estacionária; e o termo de médias móveis (MA), que captura a influência dos erros passados sobre os valores correntes da variável observada.

A aplicação adequada do modelo ARIMA requer que a série em análise seja estacionária, isto é, que propriedades estatísticas como média, variância e autocorrelação permaneçam constantes ao longo do tempo. Quando essa condição não é satisfeita, procede-se à diferenciação sucessiva da série até que a estacionariedade seja alcançada. A verificação desse requisito é usualmente realizada por meio de testes estatísticos, como o Dickey-Fuller Aumentado (ADF) ou o Phillips-Perron (PP), conforme recomendado pela literatura (Box et al., 2016).

A especificação do modelo segue a forma ARIMA(p,d,q), em que p representa a ordem da componente autorregressiva (AR), d indica o número de diferenciações aplicadas (I) e q corresponde à ordem das médias móveis (MA). Sua formulação geral é dada pela Equação (1):

$$\left(1 - \sum_{i=1}^p \phi_i L^i\right) (1 - L)^d X_t = \mu + \left(1 + \sum_{i=1}^q \theta_i L^i\right) \epsilon_t \quad (1)$$

em que L é o operador de defasagem, ϕ_i representa os coeficientes autorregressivos, θ_i corresponde aos coeficientes de médias móveis, μ é a constante do modelo, e ϵ_t é o termo de erro aleatório (ruído branco).

A construção do modelo seguiu a metodologia Box-Jenkins, composta pelas etapas de identificação, estimação, diagnóstico e validação. Inicialmente, a análise das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) indicou uma estrutura de curta memória,

caracterizada por corte abrupto nas primeiras defasagens, sinalizando compatibilidade inicial com uma especificação contendo componentes autorregressivo e de médias móveis de primeira ordem, notadamente o modelo ARIMA(1,0,1).

Na sequência, a aplicação do teste Phillips-Perron confirmou a estacionariedade da série em nível, dispensando a necessidade de diferenciação adicional e indicando, portanto, componente de integração igual a zero ($d = 0$). Com base nesse resultado, e tomando como referência a especificação inicialmente sugerida pelas funções ACF e PACF, foram estimadas diversas especificações alternativas com $d = 0$, incluindo combinações adicionais reportadas na Tabela 2.3. O objetivo desse procedimento consistiu em identificar a estrutura que apresentasse os menores valores dos critérios de informação *Akaike Information Criterion* (AIC) e *Bayesian Information Criterion* (BIC), preservando, simultaneamente, parcimônia e aderência ao comportamento observado da série.

Como etapa complementar do processo de seleção, foram aplicados testes diagnósticos aos resíduos, notadamente os testes de autocorrelação residual de Ljung-Box e de normalidade de Jarque-Bera, com a finalidade de verificar a adequação estatística das especificações estimadas. Em conjunto com os critérios de informação e com a significância estatística dos parâmetros, esses procedimentos forneceram subsídios adicionais para a definição do modelo final adotado no estudo.

Dessa forma, selecionou-se a especificação ARIMA(1,0,0), posteriormente empregada nas etapas de previsão e comparação de desempenho com as demais metodologias analisadas. Tal abordagem oferece uma base metodológica consistente para a modelagem de séries temporais estacionárias. Entretanto, em contextos mais complexos, caracterizados pela presença de não linearidades, múltiplas sazonalidades ou rupturas estruturais, modelos mais flexíveis e robustos podem oferecer vantagens adicionais, o que justifica a análise de abordagens complementares, como o *Prophet*.

2.3.2 Modelo *Prophet*

O modelo *Prophet*, desenvolvido por Taylor e Letham (2017), consiste em uma abordagem de previsão de séries temporais concebida para lidar, de forma flexível, com tendências não lineares, múltiplas sazonalidades e mudanças graduais de trajetória da série ao longo do tempo. Inicialmente proposto para aplicações empresariais de larga escala, o método passou a ser utilizado em contextos acadêmicos e aplicados por combinar desempenho preditivo consistente, elevada interpretabilidade e relativa simplicidade operacional (Taylor; Letham,

2017).

De forma geral, a formulação do *Prophet* pode ser expressa pela Equação (2):

$$y(t) = g(t) + s(t) + h(t) + \epsilon_t \quad (2)$$

em que $y(t)$ representa o valor observado da variável no tempo t ; $g(t)$ corresponde ao componente de tendência de longo prazo; $s(t)$ representa os componentes sazonais periódicos; $h(t)$ incorpora efeitos associados a feriados, eventos específicos ou regressoras adicionais, quando incluídos; e ϵ_t denota o termo de erro aleatório.

A escolha do *Prophet* neste estudo justifica-se pelas características observadas na dinâmica inflacionária brasileira, marcada por persistência, possíveis mudanças de tendência associadas ao ambiente macroeconômico e padrões sazonais recorrentes. Em comparação com modelos lineares tradicionais, como o ARIMA, o *Prophet* permite modelar conjuntamente os componentes de tendência e sazonalidade, sem depender de sucessivas transformações para a obtenção de estacionariedade, o que torna sua aplicação mais direta em séries com comportamento dinâmico. Ao mesmo tempo, preserva uma estrutura de interpretação relativamente transparente, aspecto particularmente relevante em aplicações empíricas na área econômica.

Para fins de modelagem, a base de dados foi estruturada de acordo com os requisitos da metodologia empregada, preservando a ordenação cronológica das observações e a consistência das informações utilizadas. Adicionalmente, procedeu-se à verificação da integridade da base e da ausência de valores faltantes, assegurando condições adequadas para a estimação e avaliação do modelo. Com a estrutura de dados devidamente preparada, procedeu-se à especificação inicial do modelo. Para tanto, adotou-se a tendência padrão do *Prophet* com sazonalidade anual ativada (*yearly_seasonality = True*), escolha compatível com a frequência mensal da série e com a presença de padrões inflacionários recorrentes ao longo do ano. Além disso, incorporou-se uma sazonalidade customizada denominada *monthly*, parametrizada com período médio de 30,5 dias, com o propósito de conferir maior flexibilidade ao ajuste do modelo e permitir a captura de oscilações regulares associadas ao calendário mensal, contribuindo para maior adequação da especificação às características da série analisada.

No que se refere à definição do conjunto informacional empregado, importa destacar que, embora a formulação geral do *Prophet* permita a inclusão de feriados, eventos específicos e regressoras exógenas, tais elementos não foram incorporados nesta aplicação empírica. Essa decisão metodológica teve por finalidade preservar a comparabilidade entre os modelos

avaliados no primeiro ensaio — *ARIMA*, *Prophet* e *LightGBM* —, assegurando que todos fossem estimados com base no mesmo conjunto essencial de informações, centrado exclusivamente na trajetória histórica da inflação. A inclusão desses efeitos apenas para o *Prophet* poderia introduzir assimetria informacional na comparação empírica, favorecendo artificialmente seu desempenho preditivo em relação às demais abordagens.

Definida essa estrutura informacional comum aos modelos comparados, procedeu-se à etapa de calibração dos hiperparâmetros do modelo por meio de busca em grade (*grid search*) combinada com validação cruzada temporal, utilizando as rotinas oficiais do pacote *Prophet*. Ao todo, foram avaliadas 48 combinações de hiperparâmetros, resultantes de diferentes valores atribuídos a *changepoint_prior_scale*, *seasonality_prior_scale* e *fourier_order* da sazonalidade mensal adicional. Em termos funcionais, o hiperparâmetro *changepoint_prior_scale* controla a flexibilidade da tendência estimada e, conseqüentemente, sua sensibilidade a mudanças estruturais ao longo do tempo. Por sua vez, *seasonality_prior_scale* regula a intensidade admissível dos componentes sazonais, enquanto *fourier_order* define o grau de complexidade da representação harmônica associada à sazonalidade customizada. Esse procedimento teve por finalidade selecionar, de forma sistemática, a combinação de hiperparâmetros associada ao melhor desempenho preditivo, preservando a ordem cronológica das observações e evitando o uso indevido de informações futuras no processo de validação.

No âmbito da validação empírica, adotou-se uma janela inicial de 730 dias, com avanço de 180 dias entre os sucessivos pontos de corte e horizonte de previsão de 365 dias à frente. Essa configuração resultou em 45 janelas de avaliação ao longo da amostra, preservando a ordem cronológica das observações. Desse modo, evitou-se o uso indevido de informações futuras durante a calibração do modelo, reduzindo o risco de *data leakage* e reproduzindo, de forma mais realista, o ambiente informacional característico de exercícios genuínos de previsão macroeconômica. Com base nessa estratégia, a especificação final do modelo foi definida pela combinação de hiperparâmetros que apresentou o melhor desempenho na validação cruzada temporal. Uma vez selecionada essa configuração, o *Prophet* foi reestimado com toda a amostra histórica disponível da inflação, abrangendo o período de janeiro de 2000 a novembro de 2024, e posteriormente utilizado para gerar projeções mensais para os 12 meses subsequentes, correspondentes ao intervalo de dezembro de 2024 a novembro de 2025. Esse procedimento permitiu avaliar o desempenho preditivo do método em horizonte fora da amostra.

Em síntese, a adoção do *Prophet* neste estudo justifica-se por sua elevada interpretabilidade, flexibilidade estrutural e capacidade de modelar séries temporais marcadas por componentes sazonais e mudanças graduais de tendência ao longo do tempo, atributos

particularmente relevantes para a análise da dinâmica inflacionária brasileira. Na sequência, apresenta-se o modelo *LightGBM*, utilizado como abordagem de aprendizado de máquina voltada à exploração de padrões não lineares, dependências temporais e interações complexas na série analisada.

2.3.3 Modelo *LightGBM*

O *LightGBM* (*Light Gradient Boosting Machine*), desenvolvido por Ke et al. (2017), é um algoritmo de aprendizado de máquina baseado na técnica de *gradient boosting* com árvores de decisão. Seu funcionamento consiste no ajuste sequencial de árvores, em que cada nova iteração busca corrigir os erros de predição gerados nas etapas anteriores. Como resultado, o modelo final combina múltiplas árvores em um estimador flexível, capaz de capturar relações não lineares, interações entre variáveis e padrões complexos nos dados observados, atributos particularmente úteis em aplicações de previsão com séries macroeconômicas.

Nesse contexto, o desempenho do *LightGBM* está associado a escolhas computacionais que tornam seu treinamento mais eficiente em comparação com outros algoritmos de *boosting*, reduzindo o custo computacional do ajuste. Entre essas estratégias, destacam-se o crescimento das árvores no formato *leaf-wise*, a priorização de observações mais informativas durante o processo de aprendizado e mecanismos voltados à otimização do uso de recursos em bases com maior número de atributos (Ke et al., 2017). Em termos empíricos, tais propriedades tornam o modelo especialmente atrativo em contextos nos quais a dinâmica da variável de interesse pode apresentar não linearidades, mudanças de regime e padrões sazonais de difícil representação por modelos lineares tradicionais.

Considerando essas características, a aplicação empírica do modelo exigiu a construção de atributos derivados exclusivamente da própria trajetória histórica da série, preservando o caráter univariado da análise. Dessa forma, foram incluídas variáveis de calendário, como mês, ano e trimestre; transformações cíclicas do mês, por meio de seno e cosseno; defasagens da inflação em 1, 3, 6 e 12 meses; e uma média móvel de 12 meses construída com defasagem, de modo a utilizar apenas a informação disponível até o período imediatamente anterior. Adicionalmente, incorporou-se uma medida de desvio sazonal em relação à média móvel passada, também baseada em informação defasada. Esse conjunto de atributos teve por objetivo permitir ao algoritmo aprender regularidades temporais, dependências dinâmicas e padrões sazonais recorrentes da série temporal analisada, sem recorrer à inclusão de variáveis exógenas.

Para que esses atributos refletissem adequadamente o ambiente informacional de cada

período, sua construção exigiu atenção especial em relação ao risco de vazamento de informação futura (*data leakage*). Por essa razão, as defasagens e a média móvel foram definidas com o uso de operadores de deslocamento temporal, assegurando que cada observação fosse explicada apenas por informações disponíveis até o período anterior. Após essa etapa, as primeiras observações com valores ausentes decorrentes das defasagens foram removidas, resultando em uma amostra final de 287 observações, compreendendo o intervalo de janeiro de 2001 a novembro de 2024, base efetivamente utilizada nas etapas subsequentes de modelagem.

A partir dessa base já estruturada, a divisão entre treino e teste respeitou estritamente a ordem cronológica da série. Para isso, os dados foram particionados em 80% para treinamento e 20% para teste, o que correspondeu, respectivamente, aos intervalos de janeiro de 2001 a janeiro de 2020 e de fevereiro de 2020 a novembro de 2024. Essa escolha buscou preservar a coerência temporal do exercício preditivo e impedir o uso de observações futuras no processo de aprendizagem.

Na etapa seguinte, a calibração dos hiperparâmetros do modelo foi conduzida por meio de busca em grade (*Grid Search*) combinada com validação cruzada temporal do tipo *TimeSeriesSplit*, com três partições, número definido de modo a equilibrar robustez da validação, preservação de janelas temporais representativas e viabilidade computacional. Esse procedimento teve por finalidade selecionar, de forma sistemática, a configuração associada ao melhor desempenho preditivo dentro do conjunto de treinamento, preservando a estrutura temporal dos dados em todas as etapas de validação. Adicionalmente, a adoção dessa mesma lógica de calibração utilizada em outros modelos do primeiro ensaio contribuiu para preservar a comparabilidade metodológica entre abordagens de naturezas distintas. Ao todo, foram avaliadas 26.244 combinações de hiperparâmetros, cada uma testada em três divisões temporais, totalizando 78.732 ajustes, permitindo uma avaliação abrangente das combinações testadas e uma escolha mais consistente da configuração final do modelo.

Entre os hiperparâmetros calibrados, destacam-se o número máximo de folhas por árvore (*num_leaves*), a profundidade máxima (*max_depth*), a taxa de aprendizado (*learning_rate*), a fração de atributos utilizada em cada árvore (*feature_fraction*), a fração de observações para bagging (*bagging_fraction*), a frequência de bagging (*bagging_freq*), os termos de regularização L1 e L2 (*lambda_l1* e *lambda_l2*) e o número mínimo de observações por folha (*min_data_in_leaf*). Em termos funcionais, esses parâmetros controlam a complexidade do modelo, a velocidade de aprendizagem e os mecanismos de regularização, sendo fundamentais para equilibrar capacidade preditiva e risco de sobreajuste.

Com base nesse processo de calibração, a configuração final do modelo foi selecionada a partir do menor valor de RMSE obtido na validação cruzada temporal. A partir dos resultados do *Grid Search*, o *LightGBM* foi reestimado com os hiperparâmetros escolhidos sobre todo o conjunto de treinamento e, em seguida, utilizado para gerar previsões no conjunto de teste. Posteriormente, com base no modelo otimizado, realizou-se um exercício adicional de previsão para os 12 meses subsequentes ao fim da amostra observada, abrangendo o período de dezembro de 2024 a novembro de 2025.

A geração dessas previsões futuras seguiu uma estratégia de *rolling forecast* recursivo de um passo à frente. Nesse procedimento, cada nova previsão passa a integrar o conjunto de informações utilizado para construir as defasagens dos períodos seguintes, preservando a mesma lógica da engenharia de atributos adotada na etapa de treinamento. Tal estratégia mostra-se particularmente adequada em aplicações com séries temporais, pois aproxima o exercício empírico de uma situação real de previsão, em que os valores futuros precisam ser inferidos progressivamente a partir das informações disponíveis em cada período.

No que se refere ao desempenho preditivo, a avaliação do *LightGBM* foi realizada com base no conjunto de teste, utilizando as métricas MAE, RMSE e SMAPE. Adicionalmente, aplicou-se o teste de Ljung-Box aos resíduos das previsões fora da amostra, em diferentes defasagens, com o objetivo de verificar a presença de autocorrelação serial remanescente e manter comparabilidade diagnóstica com os demais modelos analisados.

Em síntese, a utilização do *LightGBM* neste estudo justifica-se por sua elevada capacidade de modelar relações não lineares, explorar padrões temporais recorrentes a partir de atributos derivados da própria série e combinar flexibilidade preditiva com eficiência computacional, características compatíveis com a dinâmica inflacionária brasileira, marcada por persistência, sazonalidade e eventuais mudanças de trajetória ao longo do tempo. Além disso, a adoção de uma estrutura temporal rigorosa na construção dos atributos, na divisão entre treino e teste e na validação cruzada contribuiu para assegurar comparabilidade metodológica com os demais modelos avaliados. A partir dessa estrutura metodológica, a seção seguinte apresenta as métricas utilizadas para a avaliação do desempenho preditivo dos modelos estimados, estabelecendo os critérios quantitativos que fundamentam a comparação empírica entre as abordagens consideradas.

2.4 AVALIAÇÃO DE DESEMPENHO DOS MODELOS

A avaliação do desempenho dos modelos foi realizada com base em três métricas

amplamente utilizadas na literatura de séries temporais: o Erro Médio Absoluto (MAE), a Raiz do Erro Quadrático Médio (RMSE) e o Erro Percentual Absoluto Médio Simétrico (SMAPE), as quais permitem captar diferentes dimensões do erro de previsão (Hyndman; Koehler, 2006). Essas métricas apresentam propriedades estatísticas distintas, possibilitando uma análise abrangente da precisão preditiva dos modelos.

2.4.1 Erro médio absoluto (MAE)

O Erro Médio Absoluto (MAE) é uma métrica comumente utilizada na avaliação de modelos preditivos, por sua simplicidade conceitual e facilidade de interpretação. Ela representa a média das diferenças absolutas entre os valores reais e os valores estimados pelo modelo, sendo expressa nas mesmas unidades da variável analisada, conforme apresentado na Equação (3):

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

em que y_i representa o valor real observado no período i ; $\hat{y}_i$ é o valor previsto pelo modelo no mesmo período; e n corresponde ao número total de observações. Em termos analíticos, quanto menor for o valor do MAE, maior será a proximidade média entre os valores estimados e os valores reais, indicando maior acurácia preditiva do modelo.

2.4.2 Raiz do erro quadrático médio (RMSE)

A Raiz do Erro Quadrático Médio (RMSE), por sua vez, é uma métrica que penaliza com maior intensidade os erros de maior magnitude. Essa característica a torna particularmente útil em cenários nos quais grandes desvios entre os valores previstos e observados devem ser evitados, como na previsão da inflação medida pelo IPCA, em que oscilações abruptas podem comprometer a qualidade das decisões econômicas. Sua formulação é dada pela Equação (4):

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

em que y_i representa o valor real observado no período i ; $\hat{y}_i$ é o valor estimado pelo modelo no mesmo período; e n corresponde ao número total de observações. Embora o RMSE seja eficaz na identificação de erros extremos, sua sensibilidade acentuada pode dificultar a interpretação direta dos resultados. Isso ocorre porque a métrica eleva os desvios ao quadrado, amplificando a influência de *outliers* e expressando os valores em unidades quadráticas da variável. Como consequência, a análise intuitiva dos resultados pode se tornar menos acessível.

2.4.3 Erro percentual absoluto médio simétrico (SMAPE)

Enquanto o MAE e o RMSE fornecem avaliações absolutas do erro, o Erro Percentual Absoluto Médio Simétrico (SMAPE) fornece uma medida relativa do erro, ao calcular o percentual médio de desvio entre os valores previstos e observados. Essa métrica é especialmente útil para comparar modelos aplicados a séries com diferentes escalas, pois reduz distorções causadas por valores muito baixos, conforme apresentado na Equação (5):

$$\text{SMAPE} = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{(|y_i| + |\hat{y}_i|)/2} \quad (5)$$

em que y_i representa o valor real observado no período i ; $\hat{y}_i$ é o valor previsto pelo modelo no mesmo período; e n corresponde ao número total de observações.

O SMAPE é uma medida de erro especialmente adequada para séries temporais que apresentam valores nulos, negativos ou de baixa magnitude, situações em que o uso do Erro Percentual Absoluto Médio (MAPE) pode tornar-se indefinido ou apresentar instabilidade numérica. Ao empregar uma normalização simétrica baseada na média dos valores absolutos observados e previstos, o SMAPE reduz tais distorções e fornece uma medida mais robusta do erro relativo. Essa característica o torna particularmente relevante em aplicações econômicas, como na previsão da inflação, cuja dinâmica apresenta variações de baixa magnitude em determinados períodos. Definidos os critérios de avaliação, a seção seguinte apresenta os resultados empíricos dos modelos estimados, incluindo a análise exploratória da série histórica e a avaliação comparativa do desempenho preditivo das abordagens consideradas.

2.5 RESULTADOS E DISCUSSÃO


Esta seção apresenta os principais resultados da análise comparativa entre os modelos

ARIMA, *Prophet* e *LightGBM* na projeção da inflação brasileira, representada pelo IPCA. A investigação tem início com a análise descritiva da série temporal, visando identificar padrões sazonais e possíveis rupturas estruturais, seguida pela estimação dos modelos e avaliação de seu desempenho preditivo.

2.5.1 Análise exploratória da série histórica da inflação (2000–2024)

A Figura 2.1 apresenta a evolução da inflação mensal no Brasil entre janeiro de 2000 e novembro de 2024, evidenciando a presença de padrões dinâmicos complexos, caracterizados por episódios de elevada volatilidade, mudanças de regime e persistência inflacionária. Destacam-se, nesse período, eventos macroeconômicos relevantes, como a Crise Financeira Global de 2008 e a pandemia de COVID-19 em 2020, ambos indicados por linhas de referência na figura.

Figura 2.1 – Evolução da inflação mensal medida pelo IPCA no Brasil, 2000–2024.



Fonte: Elaborado pelo autor, a partir de dados do Banco Central do Brasil (BCB).

Nota: As linhas verticais pontilhadas indicam eventos econômicos relevantes: o início da crise financeira global de 2008 (linha vermelha) e o início da pandemia de COVID-19 em 2020 (linha laranja).

Nos anos iniciais da amostra (2000–2004), observa-se um ambiente de maior instabilidade inflacionária, com variações mais intensas e picos elevados. Esse comportamento pode ser associado ao processo de consolidação do regime de metas de inflação, à transição macroeconômica pós-Plano Real e à incidência de choques externos. Adicionalmente, o período foi marcado por elevada incerteza econômica, possivelmente associada ao processo eleitoral de 2002 e à subsequente transição presidencial, que contribuíram para episódios de volatilidade cambial e deterioração das expectativas, com reflexos diretos sobre a dinâmica inflacionária.

Em seguida, entre aproximadamente 2005 e 2019, verifica-se um período de relativa estabilidade, no qual a inflação oscila em torno de níveis moderados, ainda que com flutuações recorrentes, sugerindo a presença de inércia inflacionária e dependência temporal significativa. A partir de 2020, nota-se uma nova intensificação da volatilidade, provavelmente relacionada aos efeitos da pandemia, incluindo desorganização das cadeias produtivas, choques de oferta e mudanças abruptas na demanda agregada.

Além da variação ao longo do tempo, a série evidencia características típicas de processos macroeconômicos, como persistência, presença de choques transitórios e possíveis mudanças estruturais, sugerindo que a dinâmica inflacionária brasileira não pode ser adequadamente descrita por modelos estritamente lineares e estacionários ao longo de todo o período. Essas evidências reforçam a necessidade de abordagens capazes de lidar simultaneamente com dependência temporal, não linearidades e variações no regime econômico.

As estatísticas descritivas apresentadas na Tabela 2.1 corroboram os padrões observados graficamente e permitem aprofundar a caracterização da série. A média mensal do IPCA foi de 0,50%, próxima à mediana de 0,45%, indicando leve assimetria positiva, associada à ocorrência de episódios de inflação mais elevada. O desvio padrão de 0,39% e o coeficiente de variação de 78,9% indicam elevada dispersão relativa, evidenciando um comportamento marcado por significativa volatilidade ao longo do período analisado. Destacam-se ainda a presença de valores extremos, como o mínimo de -0,68%, associado a episódios pontuais de deflação, e o máximo de 3,02%, que sinaliza momentos de intensa aceleração inflacionária, refletindo a incidência de choques econômicos relevantes. Tais evidências sugerem que a inflação brasileira apresenta uma dinâmica caracterizada por assimetria, volatilidade e possíveis não linearidades, o que impõe desafios adicionais à modelagem e à previsão.

Tabela 2.1 – Estatísticas descritivas da série mensal de inflação no Brasil (2000–2024).

Estatística	Valor
Número de Observações	299
Média Mensal (%)	0,5011
Desvio Padrão (%)	0,3956
Mínimo (%)	-0,68
25%	0,26
50%	0,45
75%	0,68
Máximo (%)	3,02
Coeficiente de Variação	78,9%

Fonte: Elaborado pelo autor, a partir de dados do Banco Central do Brasil (BCB).

Em conjunto, os resultados da análise exploratória evidenciam que a série da inflação brasileira possui propriedades que dificultam sua previsão, incluindo persistência temporal, sensibilidade a choques e variações no padrão de volatilidade. Tais características justificam a adoção de diferentes abordagens metodológicas no presente estudo, combinando modelos econométricos tradicionais e técnicas de aprendizado de máquina, com o objetivo de capturar, sob diferentes perspectivas, a complexidade da dinâmica inflacionária.

Diante das características previamente observadas na série, procedeu-se à verificação de sua estacionariedade, condição particularmente relevante para a adequada especificação de modelos lineares da classe ARIMA. Para tanto, aplicou-se o teste de Phillips-Perron (PP), cuja hipótese nula corresponde à presença de raiz unitária. Os resultados indicaram rejeição dessa hipótese ao nível de 5% de significância, com estatística de teste igual a -8,5058 e valor-p inferior a 1%, considerando 20 defasagens, o que fornece evidências robustas de estacionariedade da série no período analisado.

Tabela 2.2 – Teste de raiz unitária Phillips–Perron aplicado à série mensal de inflação no Brasil (2000–2024).

Estatística do Teste	Valor-p	Número de Defasagens
-8.5058	1.20e-13	20

Fonte: Elaborado pelo autor, a partir de dados do Banco Central do Brasil (BCB).

Sob a perspectiva econômica, esse resultado sugere que, apesar das oscilações observadas ao longo da amostra, a inflação mensal brasileira apresentou comportamento de reversão à média, sem trajetória explosiva persistente no horizonte considerado. Em termos práticos, choques inflacionários tendem a exercer efeitos temporários, ainda que possam gerar impactos relevantes no curto prazo, sendo posteriormente absorvidos ao longo do tempo. Tal evidência indica que modelos ARIMA constituem ferramenta apropriada para representar a estrutura temporal da série e explorar seu conteúdo informacional para fins preditivos.

Não obstante, a dinâmica inflacionária brasileira também esteve sujeita, no período analisado, a episódios de elevada volatilidade, mudanças de regime, choques de oferta, pressões cambiais e padrões sazonais recorrentes, elementos que nem sempre são plenamente capturados por estruturas lineares tradicionais. Nesse contexto, a inclusão de metodologias mais flexíveis, como *Prophet* e *LightGBM*, mostra-se pertinente, uma vez que tais abordagens podem acomodar não linearidades, alterações graduais de tendência e interações mais complexas entre padrões temporais, ampliando o escopo comparativo do estudo e a robustez da avaliação preditiva realizada nas seções subsequentes.

2.5.2 Avaliação empírica dos modelos

Uma vez confirmada a estacionariedade da série de inflação brasileira no período analisado, deu-se início à análise comparativa dos modelos *ARIMA*, *Prophet* e *LightGBM*, com o objetivo de avaliar a capacidade preditiva de cada abordagem, tanto sob critérios estatísticos consolidados quanto sob a ótica da relevância econômica das previsões. Essa etapa do estudo buscou não apenas mensurar a acurácia dos modelos, mas também examinar sua capacidade de captar diferentes dimensões da dinâmica inflacionária, como persistência temporal, sazonalidade e eventuais mudanças estruturais no comportamento da série. Nesse sentido, a comparação entre abordagens econométricas tradicionais e técnicas de aprendizado de máquina permite uma avaliação mais abrangente da adequação metodológica de cada modelo diante da complexidade inerente à série analisada.

Para assegurar consistência metodológica, cada modelo foi estimado em versões calibradas de acordo com suas especificidades. No caso do *ARIMA*, a identificação inicial da ordem foi orientada pela análise das funções de autocorrelação (ACF) e autocorrelação parcial (PACF), sendo posteriormente comparadas especificações alternativas com base em critérios de informação e no diagnóstico dos resíduos. Para o *Prophet* e o *LightGBM*, a calibração foi conduzida por meio do ajuste de hiperparâmetros com validação cruzada temporal. Essa estratégia permitiu conciliar o rigor da modelagem econométrica com abordagens modernas de avaliação preditiva, viabilizando uma comparação mais robusta entre os modelos.


Ademais, a análise dos resíduos constituiu etapa essencial na validação das especificações estimadas. Para o *ARIMA*, aplicaram-se os testes de Ljung-Box, para detecção de autocorrelação, e de Jarque-Bera, para avaliação da normalidade dos resíduos. Já para o *Prophet* e o *LightGBM*, que não requerem a hipótese de normalidade, utilizou-se apenas o teste de Ljung-Box, com o objetivo de verificar a ausência de dependência serial nos resíduos e assegurar a adequação dinâmica das previsões. Em conjunto, esses procedimentos reforçam a confiabilidade dos resultados e a consistência da análise comparativa. Com base nessa estrutura, a seção seguinte apresenta a análise individual dos modelos, iniciando-se pelo ajuste, diagnóstico e projeções do modelo *ARIMA*.

2.5.3 Modelo *ARIMA*: ajuste, diagnóstico e projeções

O modelo *ARIMA* foi identificado a partir da análise das funções de autocorrelação (ACF) e autocorrelação parcial (PACF), cujos resultados são apresentados na Figura 2.2.

Observam-se cortes acentuados na primeira defasagem, sugerindo a presença de uma estrutura de curta memória compatível com componentes autorregressivo e de média móvel de primeira ordem. Com base nesse padrão empírico, a especificação $ARIMA(1,0,1)$ foi inicialmente considerada como candidata natural para a modelagem da série.

Figura 2.2 – Funções de autocorrelação (ACF) e de autocorrelação parcial (PACF) da inflação mensal brasileira (2000–2024).



Fonte: Elaborado pelo autor, com base nas funções de autocorrelação (ACF) e autocorrelação parcial (PACF) estimadas para a série de inflação.

Em complemento à etapa de identificação, procedeu-se à verificação formal da estacionariedade da série, condição necessária para a adequada especificação do modelo $ARIMA$. A pertinência da estimação de modelos sem diferenciação adicional foi corroborada pelo teste de Phillips–Perron, apresentado na Tabela 2.2, cujos resultados indicaram a rejeição da hipótese nula de raiz unitária ao nível de 5% de significância, fornecendo evidências de estacionariedade da série em nível. Diante desse resultado, adotou-se o componente de integração $d = 0$, restringindo a análise às especificações compatíveis com essa condição estatística.

A partir dessa configuração, avançou-se para a etapa de estimação e seleção de modelos, na qual foram consideradas diferentes especificações alternativas, com o objetivo de identificar a estrutura mais adequada à dinâmica da série inflacionária. A Tabela 2.3 apresenta os resultados comparativos com base nos critérios de informação *Akaike Information Criterion* (AIC) e *Bayesian Information Criterion* (BIC).

Tabela 2.3 – Seleção de modelos ARIMA com base nos critérios de informação AIC e BIC (2000–2024).

Modelo	AIC	BIC
ARIMA(1,0,0)	154,72	165,82
ARIMA(1,0,1)	156,67	171,47
ARIMA(2,0,0)	156,67	171,48
ARIMA(1,1,1)	158,98	170,07
ARIMA(2,0,1)	158,46	176,96
ARIMA(1,1,2)	160,95	175,74
ARIMA(2,1,1)	160,96	175,74
ARIMA(2,1,2)	162,65	181,14
ARIMA(2,1,0)	195,17	206,27
ARIMA(1,1,0)	205,71	213,11
ARIMA(1,2,1)	214,06	225,14

Fonte: Elaborado pelo autor, a partir dos resultados da estimação dos modelos ARIMA.

Os resultados indicam que a especificação ARIMA(1,0,0) apresentou, simultaneamente, os menores valores de AIC (154,72) e BIC (165,82) entre todas as estruturas avaliadas, destacando-se como a alternativa mais parcimoniosa e estatisticamente aderente ao comportamento da série. Em termos comparativos, observou-se superioridade dessa especificação em relação a todas as demais configurações testadas, o que sugere que a inclusão de parâmetros adicionais não produziu ganhos de ajuste suficientes para compensar o aumento da complexidade do modelo.

Esse achado mostra-se particularmente relevante quando comparado à especificação ARIMA(1,0,1), inicialmente sugerida na etapa de identificação com base nos correlogramas. Embora a presença de um componente de média móvel fosse plausível à luz das funções de autocorrelação e autocorrelação parcial, a evidência empírica subsequente não confirmou sua relevância estatística. Em particular, a inclusão do termo MA(1) não resultou em melhoria dos critérios de informação, tampouco em avanços consistentes no ajuste global do modelo.

Dessa forma, a escolha do ARIMA(1,0,0) não decorre apenas de sua simplicidade, mas de um processo de seleção empírica no qual essa especificação apresentou melhor desempenho relativo ao conciliar: (i) coerência com a evidência de estacionariedade da série; (ii) superioridade nos critérios de informação; e (iii) maior parcimônia estrutural, uma vez que a inclusão do termo de média móvel não gerou benefícios empíricos suficientes para justificar o acréscimo de complexidade. Assim, a adoção do modelo final mostra-se metodologicamente consistente e alinhada às boas práticas da modelagem econométrica.

Uma vez definida a especificação final, procede-se à análise dos resultados de sua estimação, apresentados na Tabela 2.4. O coeficiente autorregressivo AR(1), estimado em 0,6175, com p-valor inferior a 0,001, revela significância estatística ao nível de 1% e indica a

presença de persistência inflacionária, sugerindo que valores passados da inflação influenciam significativamente seus valores correntes.

Tabela 2.4 – Resultados da estimação do modelo ARIMA(1,0,0) para a inflação mensal brasileira (2000–2024).

Parâmetro	Coeficiente/Estatística	Erro-padrão	Estatística z	p-valor
Constante	0,5011 ***	0,052	9,626	< 0,001
AR(1)	0,6175 ***	0,040	15,317	< 0,001
σ^2	0,0961 ***	0,004	23,549	< 0,001
AIC	154,72	-	-	-
BIC	165,82	-	-	-
Ljung-Box (Q)	22,4337	-	-	0,3174
Jarque-Bera (JB)	689,37	-	-	< 0,001


Fonte: Elaborado pelo autor, a partir de resultados do modelo ARIMA estimado em sua versão final.

Nota: *** indica significância estatística a 1%.

Em termos de diagnóstico, o teste de Ljung-Box para 20 defasagens (p-valor = 0,3174) não detectou a presença de autocorrelação residual estatisticamente significativa ao nível de 5%, sugerindo que o modelo captura adequadamente a estrutura de dependência temporal da série. A variância residual estimada ($\sigma^2 = 0,0961$) também sinaliza estabilidade na dispersão dos erros, reforçando a consistência do ajuste. Por outro lado, o teste de Jarque-Bera (JB = 688,37; p-valor < 0,001) rejeita a hipótese de normalidade dos resíduos, indicando a presença de assimetria e possíveis valores extremos na série analisada. Embora essa evidência recomende cautela na interpretação inferencial, especialmente em procedimentos que pressupõem normalidade dos erros, tal resultado não compromete, por si só, a capacidade preditiva do modelo.

A Figura 2.3 apresenta o ajuste do modelo ARIMA(1,0,0) à série histórica da inflação brasileira e suas projeções para o horizonte de dezembro de 2024 a novembro de 2025. Observa-se boa aderência do modelo à trajetória da inflação em períodos de relativa estabilidade, ainda que, como esperado em uma estrutura linear e parcimoniosa, as previsões tendam a suavizar oscilações mais abruptas associadas a eventuais choques econômicos.

Figura 2.3 – Ajuste amostral e previsão da inflação mensal no Brasil pelo modelo $ARIMA(1,0,0)$ no período de 2000 a 2025.



Fonte: Elaborado pelo autor, a partir de resultados do modelo $ARIMA(1,0,0)$ estimado em sua versão final.

Para o horizonte entre dezembro de 2024 e novembro de 2025, o modelo projeta relativa estabilidade inflacionária, com flutuações contidas dentro do intervalo de previsão de 95%. Ainda assim, ressalta-se que a ocorrência de eventos exógenos — como mudanças na política monetária ou choques macroeconômicos inesperados — pode afetar a trajetória dos preços e a acurácia das previsões. Nesse sentido, os resultados devem ser interpretados como projeções condicionais à continuidade dos padrões históricos da série, sendo mais confiáveis em contextos de estabilidade e menos precisos em cenários de ruptura estrutural.

Diante disso, a avaliação quantitativa do desempenho do modelo torna-se fundamental para complementar a análise gráfica e interpretativa das projeções realizadas. As métricas apresentadas na Tabela 2.5 confirmam a adequação do modelo para previsões em contextos relativamente estáveis. O Erro Médio Absoluto (MAE), de 0,2149, indica boa proximidade entre valores ajustados e observados, evidenciando desvios médios relativamente baixos. De forma complementar, a Raiz do Erro Quadrático Médio (RMSE), de 0,3101, sugere que erros de maior magnitude são pouco frequentes, ao passo que o Erro Percentual Absoluto Médio Simétrico (SMAPE), de 24,86%, revela que, em média, os desvios percentuais correspondem a cerca de um quarto dos valores efetivamente observados.

Tabela 2.5 – Desempenho preditivo do modelo ARIMA(1,0,0) para a inflação mensal no Brasil (2000–2024).

Modelo	MAE	RMSE	SMAPE
ARIMA (1,0,0)	0,2149	0,3101	24,86%

Fonte: Elaborado pelo autor, a partir de resultados do modelo ARIMA estimado em sua versão otimizada.

Sob a perspectiva econômica, tais resultados indicam que o modelo foi capaz de reproduzir de forma satisfatória a trajetória mensal da inflação brasileira, especialmente em períodos marcados por maior previsibilidade e menor ocorrência de choques abruptos. Tendo em vista que a inflação mensal apresentou, em parcela relevante da amostra analisada, especialmente entre 2004 e 2014, variações relativamente moderadas, erros médios dessa magnitude sugerem que o modelo se mostra adequado para subsidiar exercícios preditivos de curto prazo e oferecer suporte analítico a decisões associadas à política monetária, ao monitoramento das expectativas dos agentes e ao planejamento econômico.

Em síntese, o modelo ARIMA(1,0,0) apresentou bom ajuste, elevada parcimônia e desempenho preditivo consistente, especialmente em períodos de maior estabilidade da dinâmica inflacionária. Embora a etapa inicial de identificação tenha sugerido a inclusão de um componente de média móvel, a evidência empírica posterior mostrou que sua incorporação não gerou ganhos relevantes de desempenho. Assim, a escolha final pelo ARIMA(1,0,0) revela-se metodologicamente robusta, ao combinar simplicidade estrutural, adequação estatística e melhor desempenho relativo entre as especificações avaliadas. No contexto desta pesquisa, esses resultados reforçam a utilidade de modelos lineares tradicionais como referência inicial para a previsão inflacionária, servindo também como parâmetro comparativo frente às abordagens mais flexíveis analisadas nas etapas subsequentes do estudo.


2.5.4 Modelo *Prophet*: decomposição estrutural e desempenho preditivo

Na sequência, o modelo *Prophet* foi aplicado à série da inflação brasileira com o objetivo de avaliar seu desempenho preditivo, bem como examinar suas potencialidades e limitações na modelagem de séries macroeconômicas. Para tanto, sua estimação considerou ajustes em hiperparâmetros associados aos componentes de tendência e sazonalidade, de modo a obter uma especificação aderente às características da série analisada.

Diferentemente das abordagens tradicionais, o *Prophet* realiza a decomposição explícita da série em componentes estruturais — tendência, sazonalidade e efeitos específicos —, dispensando a necessidade de transformações adicionais para garantir estacionariedade. Esse

recurso mostra-se particularmente útil diante de tendências não lineares e múltiplas sazonalidades, características frequentemente observadas em séries macroeconômicas, como a própria inflação brasileira.

Figura 2.4 – Decomposição dos componentes temporais estimados pelo modelo *Prophet* para a inflação mensal no Brasil (2000–2024).



Fonte: Elaborado pelo autor, a partir de resultados do modelo *Prophet* estimado em sua versão otimizada.

A Figura 2.4 apresenta a decomposição estrutural dos componentes estimados pelo *Prophet*, evidenciando a separação entre diferentes fatores que influenciam a trajetória inflacionária, notadamente a tendência de longo prazo e os padrões sazonais recorrentes. Essa estrutura analítica amplia o potencial interpretativo do modelo em aplicações empíricas, ao permitir distinguir, com maior clareza, movimentos associados a fatores persistentes daqueles relacionados a oscilações periódicas. No contexto do presente ensaio, tal característica mostra-se especialmente relevante, uma vez que a inflação brasileira combina elementos estruturais e conjunturais que dificultam sua previsão por modelos estritamente lineares.

No que se refere ao componente tendencial, observa-se uma trajetória gradualmente

decrecente ao longo da amostra, resultado compatível com o processo de consolidação do regime de metas de inflação adotado no Brasil, com o fortalecimento institucional da política monetária e com a redução da inflação média observada após a estabilização macroeconômica do período pós-Plano Real. Ainda que episódios pontuais de pressão inflacionária tenham ocorrido ao longo da série, o comportamento estimado sugere que tais choques não alteraram de forma permanente a direção de longo prazo dos preços.


Além da tendência, a decomposição evidencia a presença de sazonalidade anual relevante, expressa por ciclos recorrentes de maior e menor pressão inflacionária ao longo do ano. Do ponto de vista econômico, esse comportamento pode refletir reajustes tarifários concentrados em determinados meses, efeitos climáticos sobre alimentos, sazonalidade do consumo das famílias e recomposição periódica de preços administrados. A identificação desses ciclos reforça a necessidade de incorporar componentes sazonais em exercícios preditivos aplicados à inflação brasileira.

Em complemento, a componente sazonal mensal evidencia oscilações regulares intra-período, indicando que parte da dinâmica inflacionária também responde a efeitos associados ao calendário de coleta, à formação de preços em segmentos específicos e à distribuição temporal de reajustes ao longo do mês. Embora de menor magnitude relativa, tais movimentos contribuem para explicar variações de curto prazo frequentemente observadas na inflação mensal e adicionam granularidade à interpretação do comportamento da série.

Em conjunto, os resultados demonstram que o *Prophet* foi capaz de captar padrões temporais complexos presentes na série analisada, conciliando interpretabilidade e flexibilidade estrutural. No contexto comparativo deste primeiro ensaio, isso sugere que metodologias capazes de modelar explicitamente tendência e sazonalidade podem oferecer vantagens relevantes em ambientes marcados por mudanças graduais de trajetória e recorrência de movimentos sazonais, ampliando o escopo da avaliação preditiva desenvolvida neste estudo.

Com base nessas evidências, passa-se à análise do desempenho preditivo do modelo. Nesse contexto, a Figura 2.5 apresenta as projeções de inflação geradas pelo *Prophet*, contemplando a série observada, os valores ajustados e os respectivos intervalos de predição de 95%. Os resultados indicam que a calibração dos parâmetros do modelo mostrou-se relevante para aprimorar o desempenho preditivo da metodologia, ampliando sua capacidade de captar padrões sazonais recorrentes e tendências estruturais de longo prazo.

Figura 2.5 – Ajuste amostral e previsão da inflação mensal no Brasil pelo modelo *Prophet* no período de 2000 a 2025.



Fonte: Elaborado pelo autor, a partir de resultados do modelo *Prophet* estimado em sua versão otimizada.

Conforme ilustrado na Figura 2.5, o modelo apresentou ajuste robusto à série histórica da inflação medida pelo IPCA, reproduzindo de forma adequada os principais padrões sazonais e a trajetória tendencial observada ao longo da amostra. A proximidade entre valores estimados e observados sugere que o *Prophet* foi capaz de representar de maneira consistente a dinâmica inflacionária, sobretudo em períodos de maior estabilidade macroeconômica, nos quais predominam movimentos graduais e mais previsíveis dos preços.

Entretanto, em intervalos marcados por maior volatilidade, observa-se ampliação da dispersão entre valores reais e previsões, o que sugere limitações do modelo diante de choques exógenos abruptos, alterações repentinas de regime ou pressões inflacionárias não antecipadas pela informação histórica disponível. Tal resultado é coerente com o contexto brasileiro, no qual episódios de desvalorização cambial, choques de oferta e mudanças fiscais podem gerar oscilações temporárias de difícil modelagem por estruturas predominantemente aditivas.

No horizonte prospectivo de dezembro de 2024 a novembro de 2025 — destacado em vermelho no gráfico —, as previsões permanecem alinhadas ao comportamento médio recente da série, com oscilações moderadas e integralmente contidas no intervalo de predição de 95%. Sob a ótica econômica, esse comportamento sugere expectativa de continuidade do processo de estabilização inflacionária, sem evidências, segundo o modelo, de aceleração persistente dos preços no curto prazo, o que sinaliza manutenção de trajetória relativamente controlada da

inflação no período projetado.

A qualidade do ajuste do *Prophet* também foi avaliada por meio da análise dos resíduos. Conforme apresentado na Tabela 2.6, o teste de Ljung-Box indicou presença de autocorrelação residual estatisticamente significativa, com estatística de 118,93 e valor-p inferior a 1%, sugerindo que parte da estrutura temporal da inflação não foi plenamente capturada pelo modelo.

Tabela 2.6 – Teste de Ljung-Box para autocorrelação dos resíduos do modelo *Prophet* (2000–2024).

Estatística do Teste (LB)	Valor-p	Número de Defasagens
118,93	4,50e-16	20

Fonte: Elaborado pelo autor, a partir de resultados do modelo *Prophet* estimado em sua versão otimizada.

Apesar do desempenho satisfatório em termos de ajuste visual e capacidade de decomposição estrutural, a presença de autocorrelação residual indica que o modelo não capturou integralmente todos os mecanismos dinâmicos da série. Em termos econômicos, isso sugere a existência de persistência inflacionária adicional ou de fatores omitidos que continuaram influenciando os preços após a estimação.

Essa limitação aponta para possibilidades de aprimoramento em pesquisas futuras, como a incorporação de variáveis exógenas associadas à política monetária, à taxa de câmbio, aos preços internacionais ou ao nível de atividade econômica, bem como o uso de abordagens híbridas na modelagem preditiva. Tais extensões podem contribuir para previsões inflacionárias mais robustas, especialmente em contextos de maior instabilidade macroeconômica, como os observados em diferentes momentos da amostra analisada.

Na sequência, a Tabela 2.7 apresenta as métricas de desempenho preditivo do modelo *Prophet*, cujos resultados permitem avaliar, de forma objetiva, a precisão de suas estimativas. Os valores do Erro Médio Absoluto (MAE = 0,2456) e da Raiz do Erro Quadrático Médio (RMSE = 0,3412) sinalizam desempenho global consistente, ao evidenciarem desvios médios moderados entre os valores previstos e os observados. Nesse sentido, sob a perspectiva econômica, esses resultados sugerem que o modelo foi capaz de acompanhar, de forma coerente, a trajetória geral da inflação mensal ao longo do período analisado.

Tabela 2.7 – Métricas de desempenho preditivo do modelo *Prophet* para a inflação mensal no Brasil (2000–2024).

Modelo	MAE	RMSE	SMAPE (%)
<i>Prophet</i>	0,2456	0,3412	53,40

Fonte: Elaborado pelo autor, a partir de resultados do modelo *Prophet* estimado em sua versão otimizada.

Por outro lado, o Erro Percentual Absoluto Médio Simétrico (SMAPE = 53,40%) revela menor acurácia relativa, especialmente em períodos marcados por valores mais baixos da inflação ou por oscilações abruptas de curto prazo, situações em que pequenas diferenças absolutas tendem a se traduzir em erros percentuais mais elevados. Tal resultado é compatível com a natureza da série inflacionária brasileira, caracterizada por episódios alternados de estabilidade e volatilidade ao longo da amostra.

Esse desempenho era, em certa medida, esperado, uma vez que o *Prophet* foi calibrado por meio de validação cruzada temporal com janelas deslizantes, procedimento que simula condições reais de previsão sem acesso a informações futuras. Embora metodologicamente mais rigorosa, essa estratégia tende a impor maior complexidade ao exercício preditivo, sobretudo porque o acúmulo de erros ao longo do horizonte de previsão pode impactar negativamente métricas mais sensíveis à escala relativa, como o SMAPE.

Ainda assim, apesar dessas limitações, o modelo demonstrou desempenho robusto na captura de tendências e sazonalidades, destacando-se por sua flexibilidade estrutural e elevada interpretabilidade. No contexto comparativo deste estudo, o *Prophet* mostra-se particularmente útil em aplicações que demandam atualizações frequentes das previsões e decomposição explícita dos componentes temporais, configurando-se como instrumento relevante para a projeção de indicadores macroeconômicos, como a inflação. A partir dessas evidências, a seção seguinte apresenta a avaliação do modelo *LightGBM*, com ênfase em seu desempenho preditivo e na robustez das previsões frente à dinâmica inflacionária observada.

2.5.5 Modelo *LightGBM*: avaliação de desempenho e robustez preditiva

Após a avaliação dos modelos ARIMA e *Prophet*, procedeu-se à análise do desempenho preditivo do *LightGBM* na projeção da inflação brasileira, com foco na interpretação dos resultados obtidos, especialmente no que se refere à capacidade preditiva do modelo e às suas implicações econômicas.

Os resultados apresentados na Tabela 2.8 evidenciam desempenho robusto do modelo *LightGBM*, sobretudo quando se consideram a elevada volatilidade e a recorrência de choques externos que marcaram a dinâmica da inflação no Brasil ao longo do período analisado. Em termos quantitativos, o Erro Médio Absoluto (MAE) de 0,0920 ponto percentual indica que, em média, as previsões mensais diferiram menos de um décimo de ponto percentual em relação aos valores observados, magnitude reduzida para uma série historicamente sujeita a oscilações relevantes.

Tabela 2.8 – Desempenho preditivo do modelo *LightGBM* na previsão da inflação mensal no Brasil (2000–2024).

Modelo	MAE	RMSE	SMAPE
<i>LightGBM</i>	0,0920	0,1680	23,93%

Fonte: Elaborado pelo autor, a partir de resultados do modelo *LightGBM* estimado em sua versão otimizada.


De forma complementar, a Raiz do Erro Quadrático Médio (RMSE) de 0,1680 ponto percentual revela que, mesmo ao atribuir maior peso a desvios de maior magnitude, o modelo manteve nível de precisão consistente, sem comprometimento relevante de desempenho diante de erros mais expressivos. Como essa métrica penaliza erros extremos com maior intensidade, seu valor moderado sugere que o *LightGBM* apresentou boa capacidade de adaptação inclusive em períodos de maior instabilidade inflacionária, sem concentração excessiva de erros severos no horizonte avaliado.

Já o Erro Percentual Absoluto Médio Simétrico (SMAPE) de 23,93% deve ser interpretado à luz das características específicas da inflação mensal brasileira. Em séries econômicas cujos valores frequentemente se situam próximos de zero — e, em alguns momentos, assumem valores negativos — métricas percentuais tendem a se elevar mecanicamente mesmo diante de erros absolutos reduzidos. Nesse contexto, o resultado observado não compromete a qualidade preditiva do modelo; ao contrário, mostra-se compatível com aplicações em séries de baixa magnitude relativa e elevada sensibilidade percentual.

Em conjunto, essas evidências sugerem que o *LightGBM* conseguiu captar de forma eficiente parcela relevante da estrutura dinâmica da inflação brasileira no período de teste, combinando elevada precisão média com controle adequado de erros extremos. Do ponto de vista econômico, tal desempenho mostra-se particularmente relevante, uma vez que previsões mensais com desvios reduzidos tendem a contribuir para análises prospectivas mais precisas de política monetária, assegurando maior qualidade informacional para a formação de expectativas, o monitoramento conjuntural e o processo de tomada de decisão econômica.

Diante do desempenho superior observado nas métricas de avaliação, o modelo *LightGBM* foi empregado na geração das previsões prospectivas para o período de dezembro de 2024 a novembro de 2025, cujos resultados são apresentados na Figura 2.6.

Figura 2.6 – Ajuste amostral e previsão da inflação mensal no Brasil pelo modelo *LightGBM* no período de 2000 a 2025.



Fonte: Elaborado pelo autor, a partir de resultados do modelo *LightGBM* estimado em sua versão otimizada.

Os resultados demonstram que o modelo capturou de forma eficiente os principais padrões temporais e a trajetória inflacionária ao longo do período analisado, apresentando elevada aderência às oscilações observadas, inclusive em intervalos de maior volatilidade. Tal evidência reforça a capacidade preditiva da abordagem adotada e sugere que o algoritmo foi capaz de aprender regularidades relevantes da série mesmo em cenários macroeconômicos adversos e marcados por maior instabilidade conjuntural.

Para o horizonte fora da amostra (dezembro de 2024 a novembro de 2025), as projeções apresentam comportamento alinhado à média histórica recente, embora revelem leve tendência à suavização dos picos inflacionários. Esse resultado sugere expectativa de continuidade de trajetória relativamente controlada da inflação no curto prazo, sem sinais de aceleração persistente dos preços, segundo o conjunto informacional utilizado pelo modelo.

Tal desempenho do modelo pode ser atribuído às características intrínsecas do *LightGBM*, como a capacidade de modelar relações não lineares, explorar interações complexas entre variáveis derivadas da própria série e produzir estimativas com elevada acurácia. Além disso, a calibração criteriosa dos hiperparâmetros contribuiu de forma relevante para a redução dos erros preditivos, conforme evidenciado pelas métricas de avaliação apresentadas na Tabela 2.8. Dessa forma, os resultados sugerem que a combinação entre flexibilidade algorítmica, elevada capacidade preditiva e ajuste otimizado constituiu fator determinante para o desempenho superior observado.

Em etapa complementar, procedeu-se à análise dos resíduos do modelo, com o objetivo

de examinar a qualidade estatística do ajuste obtido. Embora o *LightGBM*, por sua natureza não paramétrica, não exija os pressupostos clássicos frequentemente empregados na avaliação de modelos lineares, aplicou-se o teste de Ljung-Box para investigar a eventual presença de dependência temporal residual e, adicionalmente, assegurar critério comparativo mais homogêneo em relação aos demais modelos analisados.

Tabela 2.9 – Teste de Ljung–Box para autocorrelação dos resíduos do modelo *LightGBM* (2000–2024).

Estatística do Teste (LB)	Valor-p	Número de Defasagens
19,4937	0,4900	20

Fonte: Elaborado pelo autor, a partir de resultados do modelo *LightGBM* estimado em sua versão otimizada.

Os resultados do teste de Ljung-Box indicam ausência de autocorrelação estatisticamente significativa nos resíduos para 20 defasagens (p -valor = 0,4900). Essa evidência sugere que o modelo capturou adequadamente a estrutura temporal relevante da série, reforçando a qualidade do ajuste obtido e a robustez das previsões geradas.

Em síntese, os resultados indicam que o *LightGBM* apresentou desempenho preditivo robusto e superior entre as abordagens avaliadas, combinando elevada precisão, flexibilidade algorítmica e capacidade de adaptação a diferentes regimes da série inflacionária. Esses achados ampliam as evidências favoráveis ao uso de técnicas modernas de aprendizado de máquina na previsão macroeconômica. Em termos aplicados, tais evidências reforçam o potencial do modelo como ferramenta eficiente para a modelagem da inflação, tanto em análises retrospectivas quanto em projeções futuras, qualificando-o como instrumento relevante para projeções econômicas, planejamento estratégico e processos de tomada de decisão. Diante desses resultados, a seção seguinte sistematiza a comparação entre os modelos ARIMA, *Prophet* e *LightGBM* na previsão da inflação brasileira, destacando suas diferenças em termos de acurácia preditiva, robustez e aplicabilidade prática.

2.6 COMPARAÇÃO DO DESEMPENHO PREDITIVO DOS MODELOS

A análise comparativa dos modelos ARIMA, *Prophet* e *LightGBM* evidencia diferenças relevantes em termos de desempenho preditivo, robustez e adequação metodológica à previsão da inflação no Brasil. De forma geral, o *LightGBM* apresentou os melhores resultados entre as abordagens avaliadas, destacando-se pela capacidade de captar padrões não lineares, oscilações abruptas e interações complexas presentes na dinâmica inflacionária. Essa superioridade torna-

se particularmente evidente em períodos marcados por maior instabilidade macroeconômica, como a Crise Financeira Global de 2008 e os desdobramentos econômicos associados à pandemia de COVID-19. Conforme ilustrado na Figura 2.6, o modelo foi capaz de refletir tanto os efeitos deflacionários observados no início da pandemia quanto a aceleração inflacionária subsequente, evidenciando elevada sensibilidade a choques externos e a mudanças estruturais no comportamento dos preços.

O modelo ARIMA(1,0,0), apresentado na Figura 2.3, mostrou desempenho satisfatório em períodos de maior estabilidade econômica, ajustando-se adequadamente à trajetória da inflação brasileira quando os padrões inflacionários permaneceram relativamente estáveis e recorrentes. Contudo, sua estrutura estritamente linear revelou limitações diante de choques exógenos e alterações abruptas no comportamento da série, especialmente no período posterior a 2020. Nessas circunstâncias, o modelo tendeu a suavizar as previsões e a subestimar picos inflacionários, em razão de sua dependência de relações autorregressivas lineares e da menor capacidade de captar dinâmicas não lineares mais complexas.

Por sua vez, o modelo *Prophet* (Figura 2.5) apresentou desempenho intermediário na previsão da inflação. Embora tenha registrado os maiores erros nas métricas quantitativas, especialmente no SMAPE (53,40%), essa abordagem demonstrou capacidade relevante de adaptação a mudanças graduais de tendência, sobretudo durante o período pandêmico. Sua arquitetura, baseada na decomposição explícita dos componentes da série — tendência, sazonalidade anual e sazonalidade mensal —, proporcionou maior transparência analítica e boa interpretação da dinâmica inflacionária. Ainda assim, observou-se limitação relativa na modelagem de choques abruptos, o que reduziu sua acurácia em cenários econômicos mais turbulentos.

Esses resultados confirmam que o desempenho dos modelos está diretamente associado ao contexto econômico em que são aplicados. Em cenários de estabilidade, modelos estatísticos tradicionais, como o ARIMA, tendem a ser mais eficazes em função de sua simplicidade estrutural e elevada interpretabilidade. Contudo, em ambientes marcados por alta volatilidade — como aqueles observados durante a crise de 2008 e entre 2020 e 2022 —, abordagens baseadas em aprendizado de máquina, como o *LightGBM*, revelam-se mais eficazes, uma vez que oferecem maior flexibilidade na modelagem de padrões complexos e não lineares, proporcionando ganhos significativos em acurácia preditiva.

O modelo *Prophet*, embora tenha apresentado erros mais elevados, destacou-se por sua estrutura modular e interpretável, baseada na decomposição explícita de tendência e sazonalidade. Tal característica o torna particularmente útil em aplicações que demandam

transparência metodológica, comunicação clara dos componentes subjacentes à trajetória da série temporal e atualização frequente das previsões. Em contextos institucionais, como o acompanhamento conjuntural, a elaboração de cenários prospectivos e o suporte técnico à formulação de políticas econômicas, essa interpretabilidade pode representar vantagem operacional relevante, ao facilitar a leitura dos resultados, o acompanhamento das tendências e a comunicação entre analistas e formuladores de políticas públicas.

A Tabela 2.10 sintetiza as principais evidências comparativas entre os modelos analisados, reunindo resultados quantitativos e características qualitativas que permitem avaliação abrangente do desempenho preditivo, da capacidade de adaptação a diferentes contextos macroeconômicos e da aplicabilidade prática na previsão da inflação.

Tabela 2.10 – Desempenho preditivo e comparação estrutural dos modelos ARIMA, *Prophet* e *LightGBM* na previsão da inflação no Brasil (2000–2025).

Critério	ARIMA(1,0,0)	<i>Prophet</i>	<i>LightGBM</i>
Configuração do modelo	Otimizada: ordem (p,d,q) selecionada com base nos critérios AIC/BIC	Otimizada: via calibração de hiperparâmetros	Otimizada: via calibração de hiperparâmetros
Erro Médio Absoluto (MAE)	0,2149	0,2456	0,0920
Raiz do Erro Quadrático Médio (RMSE)	0,3101	0,3412	0,1680
Erro Percentual Absoluto Simétrico (SMAPE)	24,86%	53,40%	23,93%
Capacidade de capturar tendências	Média (adequada para séries lineares)	Alta (decomposição explícita)	Alta (captura padrões não lineares)
Capacidade de modelar sazonalidade	Baixa (requer extensão SARIMA)	Alta (componente sazonal explícito)	Alta (via atributos derivados)
Sensibilidade a choques e volatilidades	Baixa (estrutura linear)	Média (ajuste por tendência e sazonalidade)	Alta (maior adaptação a mudanças abruptas)
Interpretabilidade	Alta (estrutura estatística)	Alta (componentes interpretáveis)	Média (modelo “caixa-preta”)
Recomendação de uso	Séries estáveis com padrão linear	Séries com tendência e sazonalidades	Séries complexas, voláteis, e não lineares

Fonte: Elaborado pelo autor, a partir dos resultados da pesquisa.

Nota: Em aprendizado de máquina, modelos do tipo “caixa-preta”, caracterizados por maior complexidade estrutural, tendem a apresentar menor transparência e interpretabilidade em comparação a modelos paramétricos tradicionais.

Os resultados numéricos apresentados na Tabela 2.10 confirmam a superioridade preditiva do *LightGBM*, que obteve os menores erros entre os modelos avaliados (MAE = 0,0920, RMSE = 0,1680 e SMAPE = 23,93%), evidenciando sua robustez na modelagem de

padrões não lineares e maior capacidade de adaptação a contextos de alta volatilidade. Em termos econômicos, previsões mais precisas podem contribuir para diagnósticos conjunturais mais confiáveis, melhor formação de expectativas e suporte técnico mais qualificado à condução da política monetária.

O ARIMA(1,0,0), embora tenha alcançado desempenho preditivo consistente (MAE = 0,2149; RMSE = 0,3101; SMAPE = 24,86%), mostrou-se relativamente mais adequado a contextos estáveis, dada sua estrutura linear e elevada interpretabilidade. Já o *Prophet*, apesar de registrar os maiores erros (MAE = 0,2456; RMSE = 0,3412; SMAPE = 53,40%), destacou-se pela capacidade de adaptação a mudanças de tendência e pela modelagem explícita da sazonalidade, sendo particularmente útil em aplicações que demandam atualização contínua das previsões e leitura estruturada dos componentes temporais.

De modo geral, os achados deste estudo indicam que não existe modelo universalmente superior em todas as circunstâncias, uma vez que a adequação de cada abordagem depende das características da série analisada e dos objetivos específicos da aplicação. Ainda assim, para o caso da inflação brasileira no período considerado, o *LightGBM* apresentou o melhor desempenho global, sugerindo que técnicas modernas de aprendizado de máquina podem oferecer ganhos substantivos de acurácia preditiva quando aplicadas a séries macroeconômicas complexas e sujeitas a choques externos, mudanças estruturais e oscilações conjunturais relevantes, fatores que afetam diretamente a dinâmica dos preços na economia. A partir dessa síntese comparativa, a seção seguinte apresenta as considerações finais do estudo, retomando os principais achados, suas implicações, limitações e possíveis direções para pesquisas futuras.

2.7 CONSIDERAÇÕES FINAIS

Este estudo comparou o desempenho preditivo dos modelos ARIMA, *Prophet* e *LightGBM* na projeção da inflação brasileira, medida pelo IPCA, utilizando dados históricos compreendidos entre janeiro de 2000 e novembro de 2024, com geração de previsões para o horizonte prospectivo de dezembro de 2024 a novembro de 2025. Para tanto, a análise contemplou as etapas de estimação, validação e previsão, permitindo avaliar a robustez dos modelos tanto em dados observados quanto em cenários futuros não observados. A performance preditiva dos modelos foi mensurada por meio de métricas estatísticas amplamente consolidadas na literatura — MAE, RMSE e SMAPE —, complementadas por inspeções gráficas e testes diagnósticos dos resíduos, de modo a proporcionar uma avaliação abrangente da capacidade dos modelos em representar a dinâmica inflacionária brasileira.

A partir dessa estrutura analítica, os achados deste estudo permitiram estabelecer comparação clara entre as abordagens avaliadas. De modo geral, o *LightGBM* apresentou o melhor desempenho relativo, alcançando os menores erros em todas as métricas consideradas (MAE = 0,0920; RMSE = 0,1680; SMAPE = 23,93%). Sua capacidade de modelar relações não lineares e explorar múltiplos atributos derivados da própria série possibilitou captar com maior precisão episódios inflacionários críticos, como os efeitos deflacionários observados no início da pandemia de COVID-19, em 2020, e a subsequente aceleração dos preços em 2021 e 2022. Tal desempenho o posiciona como alternativa metodologicamente robusta para exercícios preditivos de curto e médio prazo, especialmente em aplicações voltadas ao suporte de políticas monetárias mais responsivas e aos processos de tomada de decisão econômica.

O modelo ARIMA(1,0,0), por sua vez, apresentou desempenho preditivo moderado, com boa capacidade de ajuste em períodos de maior estabilidade econômica, como aqueles observados em parte relevante do intervalo compreendido entre 2004 e 2014. Sua estrutura linear e simplicidade metodológica, aliadas à clareza interpretativa dos coeficientes, tornam-no uma ferramenta particularmente útil em contextos que demandam modelos mais parcimoniosos, transparentes e estatisticamente bem fundamentados. Contudo, embora essa arquitetura favoreça a transparência analítica e interpretabilidade, ela também impõe limitações relevantes diante de rupturas estruturais, choques de oferta ou variações abruptas de preços, características cada vez mais recorrentes na conjuntura macroeconômica contemporânea.

Já o modelo *Prophet*, embora tenha apresentado os maiores erros percentuais entre as abordagens analisadas, destacou-se pela flexibilidade na decomposição dos componentes temporais e pela capacidade de adaptação a mudanças graduais de tendência. Nesse sentido, mostrou-se especialmente eficaz na representação de sazonalidades mensais e anuais, além de apresentar desempenho consistente durante o período pandêmico, ao gerar previsões coerentes diante período de elevada incerteza. Tais características o qualificam como uma ferramenta valiosa em aplicações que exigem maior transparência analítica quanto aos componentes de tendência e sazonalidade, bem como atualizações frequentes das previsões, ainda que com menor precisão no estudo em questão quando comparado a modelos mais complexos.

Do ponto de vista aplicado, os achados deste estudo apresentam implicações relevantes. Na esfera pública, a adoção de modelos mais precisos pode contribuir para melhor calibração da taxa básica de juros (Selic), aperfeiçoamento da condução da política monetária e redução da incerteza inflacionária, elementos essenciais para o ancoramento das expectativas do mercado e a estabilidade macroeconômica. No setor privado, previsões mais acuradas tendem a favorecer estratégias de precificação, gestão de riscos, planejamento financeiro e decisões de

investimento, contribuindo para maior eficiência alocativa e melhor capacidade de antecipação diante de mudanças no cenário econômico. No campo acadêmico, a pesquisa contribui para o debate acerca da incorporação de técnicas modernas de previsão em economia, evidenciando tanto os benefícios quanto as limitações inerentes a cada abordagem metodológica.

Como agenda para trabalhos futuros, recomenda-se a incorporação de variáveis exógenas aos modelos avaliados, com o objetivo de captar determinantes adicionais da dinâmica inflacionária, como a taxa de câmbio, a taxa básica de juros (Selic) e os preços internacionais de *commodities*. Ademais, sugere-se explorar abordagens híbridas que conciliem a interpretabilidade de métodos tradicionais com o poder preditivo de técnicas de aprendizado de máquina. Por fim, incentiva-se a investigação de arquiteturas baseadas em *deep learning* — como redes neurais recorrentes (RNNs) e *transformers* —, as quais representam um campo promissor para o avanço da modelagem preditiva aplicada a séries temporais macroeconômicas.

Em síntese, este trabalho reforça a importância de abordagens analíticas flexíveis e contextualizadas, capazes de refletir a complexidade da inflação brasileira contemporânea. A combinação entre métodos estatísticos consolidados na literatura e algoritmos modernos de aprendizado de máquina amplia o horizonte de previsibilidade e eleva a qualidade das análises econômicas, contribuindo para decisões mais informadas e tecnicamente fundamentadas, bem como para o fortalecimento da estabilidade macroeconômica e para a promoção do bem-estar social.

REFERÊNCIAS

- BANCO CENTRAL DO BRASIL. **Relatório de inflação**. Brasília, DF, dez. 2024. Disponível em: https://www.bcb.gov.br/conteudo/homeptbr/TextosApresentacoes/Apresentacao_RI_4T2024.pdf. Acesso em: 15 jan. 2025.
- BORGES, Mateus Penteado. **Análise e previsão de séries temporais via Facebook Prophet**. 2024. Trabalho de Conclusão de Curso (Bacharelado em Estatística) – Universidade Federal de São Carlos, São Carlos, 2024. Disponível em: <https://repositorio.ufscar.br/items/3d049ffe-d9cb-4e57-b6ec-eda6cdaaf29>. Acesso em: 15 jul. 2025.
- BOX, G. E. P.; JENKINS, G. M. **Time series analysis: forecasting and control**. San Francisco: Holden-Day, 1976.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C.; LJUNG, G. M. **Time series analysis: forecasting and control**. 5. ed. Hoboken: John Wiley & Sons, 2016.
- DIEBOLD, Francis X.; MARIANO, Roberto S. Comparing predictive accuracy. **Journal of Business & Economic Statistics**, v. 13, n. 3, p. 253–263, 1995. Disponível em: <https://doi.org/10.2307/1392185>. Acesso em: 3 out. 2025.
- FERREIRA, Bruno Paulo. **Previsão da inflação no Brasil utilizando abordagem desagregada e aprendizado de máquina**. 2023. Dissertação (Mestrado em Economia) – Insper Instituto de Ensino e Pesquisa, São Paulo, 2023. Disponível em: <https://repositorio.insper.edu.br/entities/publication/0eb60133-25ce-461e-9c63-743eda7f73da>. Acesso em: 13 dez. 2024.
- FRAINER, Guilherme da Silva. **Previsão da inflação brasileira com métodos de aprendizado de máquina**. 2024. Trabalho de Conclusão de Curso (Graduação em Ciências Econômicas) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2024. Disponível em: <http://hdl.handle.net/10183/272901>. Acesso em: 21 jan. 2025.
- HASAN, M. R. et al. **A comparative study on forecasting of retail sales**. arXiv, 2022. Disponível em: <https://arxiv.org/abs/2203.06848>. Acesso em: 9 fev. 2025.
- HAMILTON, James D. **Time series analysis**. Princeton: Princeton University Press, 1994. Disponível em: <https://press.princeton.edu/books/hardcover/9780691042893/time-series-analysis>. Acesso em: 10 abr. 2025.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. 2. ed. Monash University, 2018. Disponível em: <https://otexts.com/fpp2/>. Acesso em: 10 jan. 2024.
- HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. **International Journal of Forecasting**, v. 22, n. 4, p. 679–688, 2006. Disponível em: <https://robjhyndman.com/publications/another-look-at-measures-of-forecast-accuracy/>. Acesso em: 5 dez. 2024.
- IBM. **O que são modelos ARIMA?** IBM Think, 2024. Disponível em:

<https://www.ibm.com/br-pt/think/topics/arima-model>. Acesso em: 21 jan. 2025.

KE, Guolin et al. LightGBM: A highly efficient gradient boosting decision tree. In: CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS, 31., 2017, Long Beach, CA. **Advances in Neural Information Processing Systems**. Disponível em: <https://dl.acm.org/doi/10.5555/3294996.3295074>. Acesso em: 10 fev. 2025.

META PLATFORMS. **Prophet documentation**. Disponível em: https://facebook.github.io/prophet/docs/quick_start.html. Acesso em: 10 dez. 2024.

MICROSOFT CORPORATION. **LightGBM documentation**. Disponível em: <https://lightgbm.readthedocs.io/en/stable/>. Acesso em: 16 jan. 2025.

TAYLOR, S. J.; LETHAM, B. Forecasting at scale. **PeerJ Preprints**, 2017. Disponível em: <https://doi.org/10.7287/peerj.preprints.3190v2>. Acesso em: 3 jan. 2025.

3 PREVISÃO DA INFLAÇÃO NO BRASIL À LUZ DA CURVA DE PHILLIPS NOVO-KEYNESIANA: UMA ANÁLISE MULTIVARIADA UTILIZANDO O MODELO DE APRENDIZADO DE MÁQUINA *LIGHTGBM* (2004–2025)

Resumo: Este estudo analisa o desempenho preditivo de um modelo multivariado para a inflação brasileira à luz da Curva de Phillips Novo-Keynesiana Híbrida (CPNK-H), combinando fundamentos macroeconômicos e aprendizado de máquina. A estratégia empírica baseia-se no algoritmo *Light Gradient Boosting Machine (LightGBM)*, estimado com dados mensais do Índice Nacional de Preços ao Consumidor Amplo (IPCA) e variáveis explicativas entre janeiro de 2004 e novembro de 2024, com previsões realizadas para o horizonte de dezembro de 2024 a novembro de 2025. As variáveis explicativas, fundamentadas no arcabouço teórico da CPNK-H, incluem inflação defasada, expectativas de inflação e hiato do produto. O desempenho do modelo é avaliado por meio das métricas Erro Médio Absoluto (MAE), Raiz do Erro Quadrático Médio (RMSE) e Erro Percentual Absoluto Simétrico Médio (SMAPE), enquanto a interpretação econômica das previsões é conduzida pela técnica de valores de Shapley (SHAP). Os resultados indicam desempenho preditivo consistente do modelo, com maior contribuição das expectativas e da inércia inflacionária, além de participação complementar do hiato do produto, em consonância com evidências empíricas para a economia brasileira. Conclui-se que abordagens de aprendizado de máquina, quando orientadas por fundamentos teóricos consistentes e acompanhadas de técnicas de interpretabilidade, podem complementar de forma robusta os métodos econométricos tradicionais.

Palavras-chave: Curva de Phillips Novo-Keynesiana; inflação; *LightGBM*; aprendizado de máquina; previsão.

Abstract: This study analyzes the predictive performance of a multivariate model for Brazilian inflation in light of the Hybrid New Keynesian Phillips Curve (HNKPC), combining macroeconomic fundamentals and machine learning. The empirical strategy is based on the *Light Gradient Boosting Machine (LightGBM)* algorithm, estimated using monthly data from the Broad National Consumer Price Index (IPCA) and explanatory variables between January 2004 and November 2024, with forecasts produced for the horizon from December 2024 to November 2025. The explanatory variables, grounded in the theoretical framework of the HNKPC, include lagged inflation, inflation expectations, and the output gap. Model performance is evaluated using Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), and Symmetric Mean Absolute Percentage Error (SMAPE), while the economic interpretation of the forecasts is conducted through Shapley values (SHAP). The results indicate consistent predictive performance of the model, with greater contributions from inflation expectations and inflation inertia, along with a complementary role played by the output gap, in line with empirical evidence for the Brazilian economy. It is concluded that machine learning approaches, when guided by consistent theoretical foundations and accompanied by interpretability techniques, can robustly complement traditional econometric methods.

Keywords: New Keynesian Phillips Curve; inflation; *LightGBM*; machine learning; forecasting.

Classificação JEL: C53, E31, E52.

3.1 INTRODUÇÃO

A inflação constitui uma das variáveis macroeconômicas mais relevantes para a condução da política econômica, especialmente em países que adotam o regime de metas de inflação, como o Brasil. Nesses contextos, a credibilidade e a eficácia da política monetária dependem, em grande medida, da capacidade das autoridades de antecipar com precisão o comportamento dos preços, conferindo maior previsibilidade aos agentes econômicos, reduzindo incertezas e favorecendo um ambiente mais estável para as decisões privadas e para a formação de expectativas. Seu comportamento, frequentemente marcado por elevada variabilidade e influenciado por fatores internos e externos, afeta diretamente a alocação de recursos e a formação de preços, além de comprometer a efetividade das políticas públicas e a estabilidade macroeconômica. Em economias emergentes, como a brasileira, compreender os determinantes da inflação torna-se fundamental não apenas para o desenho e a calibração da política monetária, mas também para a gestão das expectativas de inflação e para a preservação do poder de compra da população. Nesse sentido, o desenvolvimento de instrumentos analíticos capazes de descrever e antecipar a dinâmica inflacionária de forma consistente e precisa assume papel central na macroeconomia contemporânea, ao fornecer base empírica relevante para a formulação de políticas econômicas mais eficazes e sustentáveis.

Apesar da ampla utilização de metodologias econométricas univariadas na literatura de previsão de séries temporais, essas abordagens apresentam limitações importantes quando o objetivo passa a ser avançar para uma análise multivariada ancorada em fundamentos econômicos. Em geral, tais modelos se apoiam predominantemente na trajetória passada da variável de interesse e, por construção, não incorporam de forma explícita determinantes macroeconômicos associados ao processo de formação de preços, como atividade econômica, expectativas inflacionárias e choques de oferta e demanda. Como consequência, sua capacidade de capturar mudanças estruturais e episódios de elevada instabilidade tende a ser mais restrita, sobretudo em economias emergentes, caracterizadas por maior volatilidade, recorrência de choques externos e transformações institucionais relevantes. Além disso, a centralidade das expectativas na dinâmica inflacionária — evidenciada pela crítica de Lucas (1976) e pelo desenvolvimento posterior da macroeconomia com microfundamentos — reforça a necessidade de estruturas preditivas mais abrangentes e teoricamente disciplinadas, capazes de representar com maior aderência os mecanismos econômicos subjacentes ao comportamento dos preços.

Diante dessas limitações, torna-se necessária a adoção de abordagens multivariadas mais abrangentes e flexíveis, capazes de representar, de modo mais consistente, os mecanismos

econômicos subjacentes à dinâmica inflacionária. Nesse contexto, a Curva de Phillips Novo-Keynesiana (CPNK) constitui um arcabouço teórico amplamente consolidado na macroeconomia moderna. Fundamentada em microfundamentos, como a rigidez nominal de preços à la Calvo (Calvo, 1983) e o comportamento intertemporal das firmas sob concorrência monopolística (Galí, 2015), essa formulação modela a inflação como resultado da interação entre expectativas inflacionárias, custo marginal real das firmas e choques econômicos agregados. Conforme argumentam Galí e Gertler (2000), o custo marginal real constitui o determinante teórico fundamental da inflação no modelo Novo-Keynesiano, sendo conceitualmente preferível ao hiato do produto, embora este último seja frequentemente utilizado na literatura empírica em razão de sua maior operacionalidade.

Com o objetivo de capturar a persistência inflacionária observada nos dados, Galí e Gertler (2000) propõem uma extensão da Curva de Phillips Novo-Keynesiana que incorpora um componente retrospectivo (*backward-looking*) ao processo de formação de preços. Nessa formulação, uma parcela das firmas reajusta seus preços com base na inflação passada, enquanto a parcela restante adota comportamento prospectivo (*forward-looking*). Embora o componente inflacionário inercial seja empiricamente relevante, os autores encontram evidências de predominância do componente prospectivo na dinâmica inflacionária. Diante dessas características, a formulação híbrida mostra-se particularmente adequada ao contexto brasileiro, frequentemente marcado por persistência inflacionária, mecanismos formais e informais de indexação e recorrência de choques macroeconômicos (Machado; Portugal, 2014).

Com base nesse referencial teórico e empírico, este estudo adota uma abordagem orientada pela literatura da Curva de Phillips Novo-Keynesiana Híbrida, tanto na especificação do modelo quanto na seleção das variáveis explicativas. O objetivo central consiste em analisar o desempenho preditivo de um modelo multivariado disciplinado por essa estrutura teórica, incorporando variáveis fundamentais do processo inflacionário — inflação passada, expectativas de inflação e hiato do produto. Nessa perspectiva, a CPNK-H atua como referencial conceitual para a construção de um modelo preditivo flexível e teoricamente fundamentado, estimado por meio do algoritmo *Light Gradient Boosting Machine (LightGBM)*, escolhido por sua elevada capacidade de capturar relações não lineares e interações complexas entre variáveis macroeconômicas.

A estratégia empírica adotada neste estudo baseia-se em dados mensais disponibilizados pelo Banco Central do Brasil (BCB), com início em janeiro de 2003. Como *proxy* para a atividade econômica, a medida do hiato do produto é construída a partir do Índice de Atividade Econômica do Banco Central (IBC-Br), cuja tendência é extraída por meio do filtro de Hodrick–

Prescott em sua versão *one-sided*, isto é, em tempo real. Esse procedimento preserva a restrição informacional típica de exercícios de previsão, ao evitar o uso de informações futuras na estimação da tendência. Contudo, como essa estratégia tende a implicar maior instabilidade nos períodos iniciais da amostra, em virtude do número reduzido de observações disponíveis, procedeu-se à exclusão dos doze primeiros meses da série do hiato do produto. Assim, a amostra efetivamente utilizada compreende o período de janeiro de 2004 a novembro de 2024, enquanto as previsões fora da amostra abrangem o intervalo de dezembro de 2024 a novembro de 2025. Dessa forma, as previsões são realizadas de forma condicional às trajetórias observadas das variáveis explicativas ao longo desse horizonte temporal, permitindo avaliar o desempenho preditivo do modelo fora da amostra em ambiente prospectivo.

Parte-se da hipótese de que modelos multivariados ancorados em fundamentos macroeconômicos, quando combinados a métodos flexíveis de aprendizado de máquina, podem apresentar desempenho preditivo consistente e elevada capacidade de adaptação a diferentes regimes econômicos, especialmente em economias caracterizadas por elevada volatilidade macroeconômica, como a brasileira. Adicionalmente, busca-se investigar se os padrões de atribuição preditiva aprendidos pelo modelo são economicamente coerentes com os mecanismos teóricos da Curva de Phillips Novo-Keynesiana Híbrida, por meio de técnicas de interpretabilidade baseadas em valores de Shapley, implementadas pelo método SHAP (*SHapley Additive exPlanations*).

Além desta introdução, o estudo está organizado da seguinte forma. A Seção 3.2 apresenta a fundamentação teórica, com ênfase na evolução da Curva de Phillips até sua formulação Novo-Keynesiana e em seus microfundamentos. A Seção 3.3 revisa a literatura empírica aplicada ao Brasil, destacando os principais resultados e evidências disponíveis. A Seção 3.4 descreve a proposta metodológica, detalhando o modelo empírico, a base de dados, a construção das variáveis, as métricas de avaliação e os procedimentos de interpretabilidade adotados. A Seção 3.5 apresenta e discute os resultados empíricos. Por fim, a Seção 3.6 reúne as considerações finais, sintetizando as contribuições do estudo, suas limitações e possíveis extensões para pesquisas futuras. Adicionalmente, o Apêndice B apresenta a análise exploratória das séries econômicas utilizadas no segundo ensaio, incluindo estatísticas descritivas, análise gráfica da evolução temporal e testes de estacionariedade.

Ao articular um referencial teórico consistente com ferramentas modernas de previsão e interpretabilidade, este trabalho busca contribuir para a compreensão aplicada da dinâmica inflacionária brasileira e para o aprimoramento de estratégias de previsão no debate de política econômica, fornecendo evidências empíricas que reforçam a relevância de abordagens

preditivas integradas e inovadoras no processo inflacionário.

3.2 EVOLUÇÃO TEÓRICA DA CURVA DE PHILLIPS

A Curva de Phillips, enquanto representação da relação entre inflação e desemprego, passou por um extenso processo de evolução teórica ao longo do século XX. Desde sua formulação empírica original até a versão microfundamentada contemporânea, diferentes críticas e reformulações foram incorporadas, em resposta tanto às limitações observadas em suas aplicações empíricas quanto às transformações paradigmáticas da macroeconomia.

Esta seção apresenta os principais marcos dessa trajetória, com ênfase nas transições conceituais que culminaram na consolidação da Curva de Phillips Novo-Keynesiana (CPNK) como o principal referencial teórico moderno para a análise da inflação e da política monetária.

3.2.1 A Curva de Phillips Original

A origem da Curva de Phillips remonta ao trabalho seminal de Alban William Phillips (1958), que, com base em dados do Reino Unido entre 1861 e 1957, identificou uma relação inversa entre a taxa de variação dos salários nominais e a taxa de desemprego. O resultado sugeria que, em períodos de baixo desemprego, o mercado de trabalho tende a se aquecer, ampliando o poder de barganha dos trabalhadores e pressionando os salários para cima; por outro lado, em contextos de elevado desemprego, o crescimento salarial tende a ser moderado. Essa constatação empírica foi interpretada como evidência da existência de um *trade-off* entre desemprego e crescimento nominal dos salários, constituindo a base analítica da Curva de Phillips original (Phillips, 1958).

Pouco depois, Paul Samuelson e Robert Solow (1960) reinterpretaram esse resultado, transpondo a relação observada entre salários nominais e desemprego para os preços e formulando uma versão da curva que associava diretamente inflação e desemprego. Essa abordagem ganhou destaque no debate de política econômica ao longo das décadas de 1960 e início de 1970, ao oferecer uma base empírica para decisões de política monetária e fiscal, sob a premissa de que seria possível escolher, no curto prazo, entre diferentes combinações de inflação e desemprego (Costa, 2014).

Formalmente, a versão empírica clássica da Curva de Phillips pode ser expressa pela Equação (1):

$$\pi_t = \alpha - \beta u_t \quad (1)$$

em que π_t representa a taxa de inflação no período t ; u_t é a taxa de desemprego; α é o intercepto, que indica o nível autônomo de inflação; e $\beta > 0$ expressa a sensibilidade da inflação às variações do desemprego. A equação expressa a ideia de que, quanto maior o nível de desemprego, menor tende a ser a pressão inflacionária, e vice-versa.

Apesar de seu apelo intuitivo e da aderência empírica observada nos primeiros anos, a Curva de Phillips clássica apresentava limitações teóricas relevantes, pois não incorporava explicitamente a formação de expectativas dos agentes econômicos, nem possuía fundamentos microeconômicos consistentes. Além disso, revelou instabilidade ao longo do tempo diante de choques estruturais e mudanças no regime econômico.

A crise de estagflação que afetou diversas economias avançadas na década de 1970 — caracterizada pela coexistência de inflação elevada e desemprego persistente — evidenciou as limitações do *trade-off* estático sugerido pela formulação original da Curva de Phillips. Esse episódio impulsionou o desenvolvimento de novas abordagens teóricas, baseadas na incorporação das expectativas na dinâmica inflacionária e na revisão crítica da relação empírica originalmente proposta (Galí, 2015; Blanchard, 2011).

3.2.2 O modelo aceleracionista: Friedman e Phelps

A partir do final da década de 1960, a versão original da Curva de Phillips passou a ser alvo de críticas crescentes, sobretudo em razão de sua incapacidade de explicar episódios de estagflação e da instabilidade empírica observada na relação entre inflação e desemprego. Os trabalhos de Milton Friedman (1968) e Edmund Phelps (1967) representaram uma ruptura decisiva nesse debate. De forma independente, ambos argumentaram que o *trade-off* entre inflação e desemprego não se sustentaria no longo prazo, uma vez que a formulação clássica da Curva de Phillips ignorava o papel das expectativas na formação de salários e preços pelos agentes econômicos (Blanchard, 2011).

Como desdobramento dessa crítica, Friedman introduziu o conceito de taxa natural de desemprego, definida como o nível de desemprego compatível com a estabilidade da inflação. Embora o termo NAIRU¹ (*Non-Accelerating Inflation Rate of Unemployment*) tenha se difundido posteriormente na literatura, a ideia central já estava presente em sua análise.

¹ NAIRU (*Non-Accelerating Inflation Rate of Unemployment*) refere-se à taxa de desemprego consistente com a estabilidade da inflação, isto é, ao nível de desemprego que não exerce pressão de aceleração nem de desaceleração sobre a inflação.

Segundo essa abordagem, políticas econômicas que mantêm o desemprego abaixo desse nível geram apenas efeitos temporários sobre a atividade econômica. Sob essa perspectiva, no curto prazo, uma inflação mais elevada pode reduzir o desemprego; contudo, à medida que os agentes revisam suas expectativas com base na inflação observada, salários e preços passam a ser reajustados, neutralizando gradualmente os efeitos reais da política econômica. Como resultado, emerge um processo de aceleração inflacionária, sem ganhos permanentes de produto ou emprego (Friedman, 1968; Mankiw, 2019).

Essa formulação passou a ser conhecida como Curva de Phillips aumentada pelas expectativas, ou modelo aceleracionista, pois descreve uma dinâmica na qual a inflação tende a se acelerar sempre que a taxa de desemprego se encontra abaixo de seu nível natural. Em termos analíticos, sob a hipótese de expectativas adaptativas, essa relação pode ser representada pela Equação (2), conforme discutido por Blanchard (2011) e Galí (2015):

$$\pi_t = \pi_{t-1} - \beta(u_t - u_t^*) \quad (2)$$

em que, π_t representa a taxa de inflação no período t ; π_{t-1} corresponde à inflação passada, refletindo o componente de expectativas adaptativas; u_t é a taxa de desemprego corrente; u_t^* denota a taxa natural de desemprego; e $\beta > 0$ expressa a sensibilidade da inflação ao desvio da taxa de desemprego em relação ao seu nível natural.

Essa formulação implica que, sempre que a taxa de desemprego estiver abaixo da taxa natural ($u_t < u_t^*$), a inflação tende a aumentar ao longo do tempo, caracterizando um processo de aceleração inflacionária. Como consequência, a Curva de Phillips de longo prazo assume uma inclinação vertical, indicando a inexistência de *trade-off* entre inflação e desemprego nesse horizonte. Em outras palavras, a política monetária pode afetar produto e emprego apenas no curto prazo, enquanto, no longo prazo, tende a ser neutra, reforçando a visão de Friedman e Phelps de que não existe *trade-off* permanente entre inflação e desemprego.

3.2.3 Expectativas racionais e a crítica de Lucas

A década de 1970 representou um ponto de inflexão na teoria macroeconômica, particularmente no que se refere à compreensão do processo de formação das expectativas dos agentes econômicos. A Curva de Phillips com expectativas adaptativas, embora tenha representado um avanço em relação à formulação empírica original, mostrou-se insuficiente para explicar a instabilidade observada na relação entre inflação e desemprego quando as regras

de política econômica eram alteradas de forma sistemática.

Nesse contexto, destacou-se a chamada Crítica de Robert Lucas (1976), na qual o autor argumenta que modelos econométricos baseados em relações empíricas reduzidas perdem validade preditiva quando ocorrem mudanças nas regras de política econômica, uma vez que os agentes econômicos compreendem essas alterações e ajustam seu comportamento ao antecipar suas consequências. Dessa forma, políticas conduzidas de maneira previsível tendem a ser internalizadas pelos agentes, reduzindo a eficácia de modelos que não incorporam explicitamente o processo de formação das expectativas (Barbosa, 2017).

Como consequência, essa crítica promoveu um redirecionamento metodológico profundo na macroeconomia, ao exigir que os modelos passassem a se basear em fundamentos microeconômicos explícitos, nos quais o comportamento agregado resulta das decisões otimizadoras de agentes representativos que operam sob restrições reais e nominais claramente definidas. Nesse novo paradigma teórico, as expectativas passaram a ser tratadas como racionais, isto é, formadas a partir de toda a informação disponível e do conhecimento que os agentes possuem sobre o funcionamento da economia.

No âmbito da Curva de Phillips, esse avanço conceitual deu origem a uma formulação alternativa baseada em expectativas racionais, que pode ser representada pela Equação (3), conforme apresentado em Galí (2015):

$$\pi_t = E_t[\pi_{t+1}] - \beta(u_t - u_t^*) \quad (3)$$

em que, π_t representa a inflação corrente; $E_t[\pi_{t+1}]$ corresponde à expectativa racional da inflação futura; u_t é a taxa de desemprego corrente; u_t^* denota a taxa natural de desemprego; e $\beta > 0$ é o parâmetro que mede a sensibilidade da inflação ao desvio do desemprego em relação ao nível natural.

Essa formulação desloca o foco explicativo da inflação passada para as expectativas sobre a inflação futura, estabelecendo as bases conceituais da abordagem Novo-Keynesiana. Nesse arcabouço, a inflação depende criticamente das expectativas dos agentes econômicos, de modo que a credibilidade da política monetária e sua capacidade de ancorar expectativas tornam-se elementos centrais na dinâmica inflacionária (Clarida; Galí; Gertler, 1999).

Ainda assim, embora a incorporação das expectativas racionais tenha representado um avanço teórico significativo, ela não foi capaz de explicar plenamente a persistência inflacionária observada em diversas economias. Essa limitação motivou o desenvolvimento da Curva de Phillips Novo-Keynesiana (CPNK), que combina a hipótese de expectativas racionais

com a presença de rigidez nominal nos preços, oferecendo um arcabouço microfundamentado mais adequado à dinâmica inflacionária contemporânea (Costa, 2014; Galí, 2015).

3.2.4 A Curva de Phillips Novo-Keynesiana

A consolidação da Curva de Phillips Novo-Keynesiana (CPNK) insere-se no contexto da chamada Nova Síntese Neoclássica, abordagem teórica que buscou conciliar os avanços metodológicos da Nova Macroeconomia Clássica — como expectativas racionais, comportamento otimizador e microfundamentação rigorosa — com elementos centrais da tradição keynesiana, especialmente a presença de rigidez nominal de preços e salários.

Conforme discutem Jordi Galí (2015) e Costa (2014), essa síntese representou um marco na evolução da teoria macroeconômica ao substituir formulações empíricas reduzidas por modelos derivados explicitamente de fundamentos microeconômicos. Nesse tipo de abordagem, o comportamento agregado da economia é obtido a partir das decisões intertemporais de agentes representativos, modeladas por meio de funções de utilidade e de lucro.

Inserida nesse contexto, a CPNK constitui a primeira formulação da Curva de Phillips derivada explicitamente de um modelo de otimização intertemporal, no qual firmas monopolisticamente competitivas enfrentam restrições nominais na fixação de preços. A rigidez de preços é usualmente modelada segundo o mecanismo proposto por Calvo (1983), no qual apenas uma fração aleatória de empresas consegue reajustar seus preços em cada período. Como consequência, parte das firmas mantém preços previamente definidos, gerando inércia inflacionária mesmo quando os agentes formam expectativas racionais sobre as condições futuras da economia.

A equação canônica da CPNK, conforme apresentada por Jordi Galí e Mark Gertler (2000) e posteriormente sistematizada por Galí (2015), pode ser representada pela Equação (4):

$$\pi_t = \beta E_t[\pi_{t+1}] + \kappa x_t \quad (4)$$

em que π_t representa a taxa de inflação corrente; $E_t[\pi_{t+1}]$ corresponde à expectativa racional da inflação futura; x_t denota o hiato do produto, frequentemente utilizada na literatura empírica como aproximação do custo marginal real das firmas; β é o fator de desconto intertemporal; e κ mede a sensibilidade da inflação ao hiato do produto.

Essa estrutura evidencia o caráter prospectivo da inflação, reforçando o papel central

das expectativas na dinâmica de formação dos preços. Além disso, a presença simultânea de rigidez nominal e de concorrência imperfeita implica que, no curto prazo, a política monetária pode produzir efeitos reais sobre o produto e o emprego, mesmo sob a hipótese de expectativas racionais.

3.2.5 A Curva de Phillips Novo-Keynesiana Híbrida

Embora a formulação canônica da Curva de Phillips Novo-Keynesiana (CPNK) represente um avanço teórico importante ao incorporar expectativas racionais e fundamentos microeconômicos explícitos, sua versão puramente prospectiva mostrou-se limitada para reproduzir uma característica amplamente documentada da inflação observada em dados macroeconômicos: a persistência inflacionária. Em diversas economias, inclusive emergentes, a dinâmica da inflação revela forte dependência de sua própria trajetória passada, fenômeno frequentemente associado à presença de mecanismos de indexação, rigidez contratual ou heterogeneidade na formação de expectativas pelos agentes econômicos.

Diante dessa limitação, Jordi Galí e Mark Gertler (2000) propuseram uma extensão da Curva de Phillips Novo-Keynesiana, denominada Curva de Phillips Novo-Keynesiana Híbrida. Nesse modelo, coexistem dois tipos de firmas no processo de formação de preços. Uma fração $1-\omega$ das firmas apresenta comportamento prospectivo, ajustando seus preços de maneira ótima com base nas expectativas sobre custos marginais futuros, conforme o mecanismo de rigidez nominal proposto por Calvo (1983). Por sua vez, a fração restante, ω , adota comportamento retrospectivo, reajustando seus preços com base em uma regra simples associada à inflação observada no período anterior.

Essa heterogeneidade no comportamento das firmas gera uma dinâmica inflacionária que combina elementos prospectivos e inerciais, permitindo representar de forma mais realista a persistência inflacionária observada empiricamente, ainda que o componente prospectivo permaneça predominante. A equação da Curva de Phillips Novo-Keynesiana Híbrida, derivada desse arcabouço teórico, pode ser representada pela Equação (5), conforme Galí e Gertler (2000):

$$\pi_t = \gamma_b \pi_{t-1} + \gamma_f E_t[\pi_{t+1}] + \lambda mc_t \quad (5)$$

em que, π_t representa a inflação no período t ; π_{t-1} corresponde a inflação passada; $E_t[\pi_{t+1}]$ representa a expectativa racional da inflação no período seguinte; e mc_t denota o custo marginal

real das firmas. Os parâmetros γ_f e γ_b indicam, respectivamente, os pesos das expectativas futuras e da inflação passada na determinação da inflação corrente, enquanto λ mede a sensibilidade da inflação às variações do custo marginal real das firmas.

Embora o custo marginal real constitua a variável fundamental na formulação teórica do modelo, a literatura empírica frequentemente utiliza o hiato do produto como aproximação dessa variável, dada a dificuldade de mensuração direta do custo marginal agregado. Essa estratégia permite operacionalizar o modelo em aplicações macroeconômicas, mantendo consistência com os fundamentos teóricos da Curva de Phillips Novo-Keynesiana.

Em síntese, a evolução teórica da Curva de Phillips evidencia a crescente sofisticação dos modelos explicativos da inflação, culminando na formulação Novo-Keynesiana — ancorada em expectativas racionais, rigidez nominal e fundamentos microeconômicos explícitos — e em sua versão híbrida, que estende esse arcabouço ao incorporar a persistência inflacionária observada empiricamente. Nesse sentido, essa abordagem mantém consistência com a teoria moderna da política monetária e apresenta maior aderência empírica na análise da dinâmica inflacionária, sobretudo em economias emergentes, caracterizadas por elevada volatilidade, recorrência de choques e mudanças estruturais. Com base nesse referencial teórico, a seção seguinte apresenta as evidências empíricas da Curva de Phillips Novo-Keynesiana para o caso brasileiro.

3.3 EVIDÊNCIAS EMPÍRICAS DA CURVA DE PHILLIPS NOVO-KEYNESIANA NO BRASIL

A aplicação da Curva de Phillips Novo-Keynesiana (CPNK) no Brasil tem sido amplamente investigada na literatura empírica. Embora os estudos adotem diferentes abordagens metodológicas, observa-se convergência quanto à utilidade do arcabouço Novo-Keynesiano para explicar a dinâmica inflacionária no país. De modo geral, as evidências revelam significativa heterogeneidade metodológica nas estratégias de estimação, sobretudo no que se refere à escolha das *proxies* para o hiato do produto e ao tratamento das expectativas de inflação e dos mecanismos de inércia inflacionária.

Entre os trabalhos pioneiros nesse campo, destaca-se o estudo de Muinhos e Alves (2003), desenvolvido no âmbito do Banco Central do Brasil. A partir de uma função de produção do tipo Cobb–Douglas, os autores constroem uma medida de produto potencial e, com base nessa estimativa, especificam uma Curva de Phillips híbrida para a inflação de preços livres medida pelo IPCA. Nessa especificação, são incorporados componentes retrospectivos e

prospectivos das expectativas de inflação, o hiato do produto e um termo de repasse cambial (*exchange rate pass-through*), associado à taxa de câmbio e aos preços externos. A partir dessa estrutura, a equação é estimada por meio de Mínimos Quadrados em Dois Estágios (MQ2E), cujos resultados mostram que o componente prospectivo das expectativas é estatisticamente significativo e quantitativamente mais relevante do que o componente inercial, enquanto o hiato do produto apresenta apenas significância marginal, o que sugere um papel empírico limitado na explicação da inflação de preços livres no período analisado.

Na sequência, Schwartzman (2006) amplia essa abordagem ao utilizar dados desagregados de preços e modelar expectativas futuras por meio de um modelo de Vetores Autorregressivos (VAR). Como medida de atividade econômica, o autor utiliza a taxa de utilização da capacidade instalada da indústria, divulgada pela Fundação Getúlio Vargas (FGV), a qual se mostra estatisticamente significativa e mais informativa do que medidas tradicionais de hiato do produto. Os resultados evidenciam a relevância da persistência inflacionária e das expectativas de inflação, além da não rejeição da hipótese de verticalidade da curva de Phillips no longo prazo, reforçando o papel central das expectativas na dinâmica inflacionária brasileira.

Avançando nesse debate, Alves (2011) estima a versão híbrida da Curva de Phillips Novo-Keynesiana para o Brasil no período de 1995 a 2010, com dados trimestrais. Para isso, o autor utiliza diferentes medidas do hiato do produto — obtidas por meio do filtro Hodrick–Prescott e da decomposição de Watson —, bem como distintos métodos de estimação, incluindo MQO, MQ2E e o Método dos Momentos Generalizados (GMM). Os resultados mostram que tanto a inflação passada quanto as expectativas de inflação são estatisticamente significativas nas especificações híbridas, enquanto o coeficiente do hiato do produto permanece estatisticamente insignificante. Esses achados evidenciam a relevância conjunta da inércia inflacionária e das expectativas na determinação da inflação, sugerindo que a dinâmica inflacionária brasileira é melhor descrita por uma versão híbrida da CPNK.

Nos anos seguintes, observa-se um avanço nas contribuições empíricas, marcado pela adoção de técnicas mais flexíveis e pela incorporação de estruturas dinâmicas mais sofisticadas na análise da inflação. Nesse contexto, Leal (2014) estima uma Curva de Phillips Novo-Keynesiana híbrida para o Brasil no período de 2000 a 2013, por meio de um modelo em espaço de estados, utilizando o Filtro de Kalman para avaliar a estabilidade dos parâmetros ao longo do tempo. O autor testa três *proxies* para o hiato do produto — hiato do PIB, da produção industrial e da utilização da capacidade instalada (UCI). Os resultados indicam que as estimativas são pouco sensíveis à escolha da *proxy* para o hiato do produto, com evidências de

significância estatística do *trade-off* entre inflação e atividade econômica em todas as especificações consideradas, além de uma leve superioridade do modelo baseado na UCI, segundo critérios de informação. Ademais, os achados sugerem que os parâmetros associados às expectativas e à inércia inflacionária apresentam magnitudes muito próximas, evidenciando a coexistência dos componentes retrospectivos e prospectivos na determinação da dinâmica inflacionária.

No mesmo período, Machado e Portugal (2014) estimam curvas de Phillips em forma reduzida, com componentes não observados, também em espaço de estados e com uso do Filtro de Kalman, incorporando expectativas de inflação oriundas da Pesquisa Focus. Como medidas de atividade econômica, são utilizados hiatos do PIB mensal (PIB-M), do Índice de Atividade Econômica do Banco Central (IBC-Br) e desvios da utilização da capacidade instalada (UCI). Os resultados indicam que a inclusão das expectativas melhora o ajuste do modelo e que, embora os coeficientes associados ao PIB-M e à UCI sejam positivos, apenas o hiato baseado no IBC-Br apresenta relação estatisticamente significativa com a inflação. Adicionalmente, os autores encontram evidências de redução gradual da sensibilidade da inflação à atividade econômica, consistente com um processo de achatamento da curva de Phillips no Brasil. Em relação aos estudos anteriores, o trabalho aprofunda a análise ao explorar diferentes indicadores mensais de atividade econômica, evidenciando mudanças na inclinação da curva ao longo do tempo.

Complementarmente, Costa (2014) estima uma especificação *forward-looking* da Curva de Phillips Novo-Keynesiana para o Brasil, utilizando dados mensais no período de 2002 a 2014 e o método de Mínimos Quadrados Ordinários (MQO). Nessa abordagem, a inflação é modelada como função das expectativas inflacionárias extraídas da Pesquisa Focus e da taxa de desemprego em relação à NAIRU. Os resultados apontam elevada significância estatística das expectativas de inflação, ao passo que o termo associado ao desemprego não se mostra estatisticamente relevante. Esses achados reforçam o papel central das expectativas na dinâmica inflacionária e, simultaneamente, sugerem uma limitada capacidade explicativa do mercado de trabalho nessa especificação. Em contraste com os modelos em espaço de estados, o estudo adota uma abordagem mais parcimoniosa, ainda que com menor capacidade de capturar dinâmicas estruturais mais complexas.

Também com foco na sistematização da literatura, Scandolara, Bourscheidt e Nunes (2014) realizam uma revisão bibliográfica abrangente sobre a Curva de Phillips e sua aplicabilidade ao Brasil, destacando a elevada heterogeneidade metodológica dos estudos empíricos, tanto na escolha das *proxies* para a atividade econômica quanto no tratamento das

expectativas inflacionárias. Os autores ressaltam que essa diversidade dificulta a obtenção de uma especificação consensual para a economia brasileira. Ao mesmo tempo, reforçam o papel central das expectativas e a recorrente fragilidade empírica do hiato do produto nas diferentes especificações estimadas para o país, em linha com os achados empíricos previamente discutidos.

Mais recentemente, Roque Mendes (2021) estima a Curva de Phillips Novo-Keynesiana padrão de Galí e Gertler (2000), adotando a abordagem de Barnichon e Mesters (2020), baseada na identificação por choques monetários e em inferência robusta à presença de instrumentos fracos. Os resultados apontam efeitos positivos e estatisticamente significativos dos componentes retrospectivos e prospectivos sobre a inflação, além de evidências de que abordagens convencionais tendem a superestimar a inércia inflacionária e a subestimar o papel das expectativas futuras na dinâmica inflacionária. Em linha com parte significativa da literatura, o hiato do produto apresenta coeficiente estatisticamente nulo, sugerindo papel limitado da atividade econômica no processo inflacionário brasileiro.

Em síntese, as evidências empíricas apresentadas para o Brasil convergem para a conclusão de que a Curva de Phillips Novo-Keynesiana — especialmente em sua versão híbrida — constitui um arcabouço teórico e empírico adequado para compreender a dinâmica da inflação e o processo de formação de preços na economia brasileira. De modo geral, observa-se relativo consenso quanto ao papel central das expectativas de inflação e da inflação passada, ao passo que as medidas de atividade econômica apresentam menor robustez empírica na determinação da inflação.

Além disso, a análise cronológica da literatura evidencia uma clara evolução metodológica nos estudos aplicados à Curva de Phillips para o Brasil. Os trabalhos iniciais concentram-se em especificações estruturais relativamente simples, com ênfase na decomposição entre componentes prospectivos e retrospectivos da inflação. Em seguida, pesquisas posteriores passam a explorar múltiplas *proxies* para o hiato do produto e diferentes métodos de estimação. Mais recentemente, observa-se a incorporação de modelos em espaço de estados, técnicas mais robustas de identificação e maior atenção a problemas econométricos, como endogeneidade e instrumentos fracos. Essa trajetória reflete um movimento de crescente refinamento analítico e, ao mesmo tempo, reforça a robustez de um resultado central: a predominância das expectativas e da inércia inflacionária na determinação da inflação no Brasil.

Diante desse conjunto de evidências, reforça-se a necessidade de abordagens empíricas flexíveis e robustas para a previsão da inflação brasileira, capazes de acomodar, de forma mais consistente e precisa, fenômenos como não linearidades, quebras estruturais, mudanças de

regime e interações complexas entre variáveis macroeconômicas que influenciam a dinâmica dos preços, fundamentos que orientam a estratégia empírica desenvolvida na próxima seção.

3.4 PROPOSTA METODOLÓGICA

Esta seção apresenta a estratégia metodológica adotada para a previsão da inflação brasileira. Inicialmente, descreve-se o modelo teórico de referência; em seguida, são detalhadas a especificação empírica, as fontes de dados utilizadas e o processo de construção das variáveis. Na sequência, apresentam-se o modelo de aprendizado de máquina empregado e os procedimentos de estimação e validação adotados. Por fim, discutem-se os critérios de avaliação do desempenho preditivo e os métodos de interpretabilidade utilizados na análise dos resultados.

Nesse contexto, a abordagem proposta fundamenta-se na Curva de Phillips Novo-Keynesiana (CPNK), cuja microfundamentação, discutida nas seções anteriores, orienta a seleção das variáveis explicativas e estrutura sua aplicação em um ambiente de modelagem preditiva baseado em aprendizado de máquina. A operacionalização empírica desse arcabouço é realizada por meio do algoritmo *Light Gradient Boosting Machine (LightGBM)*, selecionado por sua elevada capacidade de modelar relações não lineares, capturar interações complexas e identificar padrões dinâmicos nos dados, características frequentemente observadas em séries inflacionárias, como a brasileira.

Para viabilizar essa estratégia empírica, os procedimentos adotados — incluindo o tratamento dos dados, a estimação do modelo, a validação temporal e as análises de interpretabilidade — foram implementados na linguagem de programação *Python*, no ambiente *Google Colab*. Essa escolha assegura reprodutibilidade, consistência metodológica e aderência às boas práticas em exercícios de previsão, contribuindo para a obtenção de estimativas mais robustas e confiáveis. Ademais, a estrutura computacional adotada favorece a rastreabilidade das etapas analíticas, ampliando a transparência na organização dos dados, na calibração do modelo e na interpretação dos resultados.

3.4.1 Modelo teórico

A modelagem empírica deste estudo fundamenta-se na Curva de Phillips Novo-Keynesiana Híbrida (CPNK-H), apresentada na Equação (5). Essa formulação sintetiza os mecanismos centrais da teoria Novo-Keynesiana ao combinar um componente prospectivo

associado às expectativas de inflação futura, um componente inercial vinculado à inflação passada e o papel do custo marginal real na determinação da dinâmica inflacionária. A incorporação de expectativas quanto à inflação futura nesse arcabouço, conforme enfatizado por Clarida, Galí e Gertler (1999), fornece fundamentação teórica sólida para a inclusão de variáveis antecipatórias na modelagem empírica da inflação, reforçando a consistência entre a teoria macroeconômica e as estratégias econométricas de previsão.

Partindo dessa estrutura teórica, a implementação empírica do modelo requer a escolha de uma *proxy* para o custo marginal real, uma vez que essa variável não se encontra diretamente mensurável. No âmbito da Curva de Phillips Novo-Keynesiana, constitui-se prática consolidada na literatura aproximá-la pelo hiato do produto, visto que essa medida captura, de forma agregada, as pressões de demanda na economia e o desvio do nível de atividade em relação ao produto potencial, sendo amplamente utilizada em aplicações empíricas.

Assim, tomando como referência a Equação (5), adota-se neste estudo uma especificação empírica na qual o custo marginal real é representado pelo hiato do produto. Além disso, a fim de respeitar o *timing* informacional inerente a exercícios de previsão e reduzir potenciais problemas de endogeneidade, o hiato do produto passa a ser incorporado na forma defasada (x_{t-1}). Adicionalmente, a presença simultânea de termos prospectivos e defasados na especificação empírica está em consonância com a literatura Novo-Keynesiana, na qual a dinâmica inflacionária resulta da interação entre expectativas futuras e mecanismos de inércia (Galí; Gertler, 2000; Clarida; Galí; Gertler, 1999).

Essa escolha permite preservar o vínculo conceitual entre o nível de atividade econômica e a dinâmica inflacionária, ao mesmo tempo em que mantém consistência com a natureza prospectiva do exercício preditivo desenvolvido. Dessa forma, a especificação empírica adotada pode ser representada pela Equação (6):

$$\pi_t = \gamma_b \pi_{t-1} + \gamma_f E_t[\pi_{t+1}] + \kappa x_{t-1} + \varepsilon_t \quad (6)$$

em que, π_t representa a taxa de inflação no período t ; π_{t-1} corresponde à inflação passada; $E_t[\pi_{t+1}]$ denota a expectativa racional da inflação futura; x_{t-1} representa o hiato do produto defasado em um período; e ε_t captura choques exógenos que podem afetar a dinâmica inflacionária, como variações nos preços de *commodities* ou nos preços internacionais do petróleo. Os parâmetros γ_f e γ_b indicam, respectivamente, os pesos associados às expectativas futuras e à inflação passada na determinação da inflação corrente, enquanto κ mede a sensibilidade da inflação às variações do hiato do produto.

A adoção dessa especificação mostra-se particularmente adequada ao contexto da economia brasileira, caracterizada pela presença de mecanismos formais e informais de indexação, elevada persistência inflacionária e recorrência de choques de oferta, como variações cambiais, reajustes de preços administrados e oscilações nos mercados internacionais de *commodities*, conforme evidenciado pela literatura empírica aplicada ao país (Machado; Portugal, 2014).

3.4.2 Especificação empírica do modelo

A especificação empírica de referência decorre da formulação teórica da Curva de Phillips Novo-Keynesiana híbrida apresentada na seção anterior, sendo adaptada para incorporar variáveis observáveis em frequência mensal. Essa representação atua como base conceitual para a estrutura do exercício preditivo e para a seleção das variáveis explicativas utilizadas no modelo de aprendizado de máquina estimado por meio do algoritmo *LightGBM*.

Nesse contexto, a especificação empírica adotada pode ser representada pela Equação (7):

$$\pi_t = \beta_0 + \beta_1\pi_{t-1} + \beta_2E_t[\pi_{t+1}] + \beta_3x_{t-1} + \varepsilon_t \quad (7)$$

em que, π_t representa a inflação no período t ; π_{t-1} corresponde à inflação passada; $E_t[\pi_{t+1}]$ denota as expectativas de inflação futura; x_{t-1} é o hiato do produto defasado em um período; e ε_t corresponde ao termo de erro, que captura choques não modelados capazes de afetar a dinâmica inflacionária. Os coeficientes β_1 , β_2 e β_3 refletem, respectivamente, a sensibilidade da inflação à inércia inflacionária, às expectativas de inflação e ao hiato do produto, enquanto β_0 representa o intercepto da equação.

Assim, a Equação (7) constitui uma representação simplificada do mecanismo teórico descrito na subseção anterior e estabelece o arcabouço conceitual que orienta a especificação empírica do modelo e a definição das variáveis utilizadas no exercício preditivo. As fontes de dados, os procedimentos de construção das variáveis e o tratamento das séries são descritos na seção seguinte.

3.4.3 Fontes de dados e construção das variáveis

A base de dados utilizada neste estudo compreende observações mensais do Índice

Nacional de Preços ao Consumidor Amplo (IPCA), disponíveis entre janeiro de 2003 e novembro de 2024. A partir desse conjunto de informações, o período de estimação abrange janeiro de 2004 a novembro de 2024, enquanto as previsões fora da amostra correspondem ao intervalo de dezembro de 2024 a novembro de 2025. Esse delineamento empírico permite avaliar o desempenho do modelo tanto no ajuste dentro da amostra quanto em um ambiente genuinamente prospectivo, preservando a ordem temporal das informações disponíveis.

A partir dessa definição temporal e em consonância com os objetivos empíricos do estudo, as variáveis utilizadas derivam diretamente da formulação da Curva de Phillips Novo-Keynesiana Híbrida (CPNK-H) e incluem a inflação corrente (π_t), mensurada pelo Índice Nacional de Preços ao Consumidor Amplo (IPCA); a inflação defasada em um período (π_{t-1}), que captura o componente de inércia inflacionária; as expectativas de inflação para o período seguinte ($E_t[\pi_{t+1}]$); e o hiato do produto (x_{t-1}). Todas as variáveis foram obtidas a partir de fontes oficiais e submetidas a procedimentos rigorosos de tratamento e padronização, assegurando consistência temporal, alinhamento informacional e comparabilidade entre os indicadores.

No caso específico das expectativas de inflação, sua construção foi realizada a partir da Pesquisa Focus do Banco Central do Brasil, respeitando estritamente o *timing* informacional compatível com um exercício de previsão. Mais especificamente, para cada mês t , utilizou-se a mediana das expectativas observadas no próprio mês para a inflação do período imediatamente seguinte, isto é ($E_t[\pi_{t+1}]$). Com isso, a variável de expectativas passa a refletir exclusivamente o conjunto de informações disponível aos agentes no momento da previsão, sem qualquer utilização de inflação realizada futura ou de revisões posteriores que pudessem contaminar a estrutura informacional da amostra.

Do ponto de vista operacional, os dados da Pesquisa Focus foram inicialmente organizados por janelas temporais, padronizados em frequência mensal e, em seguida, consolidados em uma única série histórica. A partir dessa base, para cada mês de referência, foram consideradas exclusivamente as previsões reportadas nesse mesmo mês que se referem à inflação esperada para o período imediatamente subsequente ($t+1$). Em seguida, calculou-se a mediana dessas previsões, obtendo-se uma única medida representativa das expectativas inflacionárias para cada período.

Essa estratégia metodológica é particularmente relevante, pois elimina o risco de vazamento de dados (*data leakage*) associado ao uso indevido de informações não disponíveis no momento da previsão. Dessa forma, a variável expectativas de inflação ($E_t[\pi_{t+1}]$) mantém plena coerência com a estrutura temporal da CPNK-H e com a lógica do experimento empírico,

configurando-se como uma medida efetivamente prospectiva das expectativas inflacionárias.

No que se refere ao hiato do produto, sua construção baseia-se no Índice de Atividade Econômica do Banco Central (IBC-Br), previamente ajustado sazonalmente. A extração da tendência foi realizada por meio do filtro de Hodrick–Prescott em sua versão em tempo real (*one-sided*), utilizando-se o parâmetro de suavização $\lambda=129.600$, apropriado para séries em frequência mensal. A adoção dessa abordagem assegura a preservação da restrição informacional típica de exercícios de previsão, uma vez que impede a utilização de informações futuras na estimação da tendência da série.

Ainda assim, nos períodos iniciais da amostra, a tendência estimada do hiato do produto tende a apresentar maior instabilidade, em função do número reduzido de observações disponíveis para o cálculo do filtro. Esse comportamento está associado ao conhecido problema de ponto inicial em métodos de extração de tendência em tempo real (Hodrick; Prescott, 1997; Banco Central do Brasil, 2024).

A inclusão de defasagens da inflação e do hiato do produto neste estudo empírico é justificada tanto por fundamentos teóricos quanto empíricos. A defasagem da inflação incorpora o componente inercial do processo inflacionário, associado à rigidez de preços e aos mecanismos de indexação característicos da economia brasileira. Por sua vez, a defasagem do hiato do produto contribui para mitigar potenciais problemas de endogeneidade, além de preservar a ordem temporal das informações disponíveis aos agentes econômicos e refletir a transmissão gradual das condições de atividade econômica para a dinâmica dos preços, conforme evidenciado por Galí e Gertler (2000).

O Quadro 3.1 apresenta a descrição detalhada das variáveis no estudo, suas respectivas fontes de dados e as principais características das séries empregadas na análise empírica.

Quadro 3.1 – Descrição das variáveis, fontes de dados e período de análise utilizado no estudo (2004–2025).

Variável	Código/ Origem	Unidade	Frequência	Período	Observações
Inflação (π_t)	433 (SGS/BCB)	% mensal	Mensal	01/2004 a 11/2025	Variável dependente principal, medida pelo IPCA
Inflação passada (π_{t-1})	Derivada do IPCA	% mensal	Mensal	01/2004 a 11/2025	Primeira defasagem do IPCA, captando a inércia inflacionária
Expectativa de inflação ($E_t[\pi_{t+1}]$)	Pesquisa Focus (BCB)	% mensal	Mensal	01/2004 a 11/2025	Mediana das expectativas de inflação (IPCA) coletadas no mês t para o mês t + 1
Hiato do produto (x_{t-1})	IBC-Br – 24364 (SGS/BCB)	Índice	Mensal	01/2004 a 11/2025	Proxy obtida por meio do filtro HP (one-sided, $\lambda=129.600$), com defasagem de um período

Fonte: Elaborado pelo autor, a partir de dados do Banco Central do Brasil (BCB).

Nota: A base final do estudo compreende o período de janeiro de 2004 a novembro de 2025. O modelo foi estimado com dados disponíveis até novembro de 2024, enquanto a avaliação fora da amostra contempla previsões para o intervalo entre dezembro de 2024 e novembro de 2025.

Por fim, a sistematização apresentada no Quadro 3.1 evidencia a consistência e a robustez da base de dados construída, assegurando o adequado alinhamento entre a formulação teórica da Curva de Phillips Novo-Keynesiana Híbrida e as variáveis observáveis disponíveis. Essa estrutura fornece, portanto, o suporte empírico necessário para a estimação do modelo e para a avaliação rigorosa de sua capacidade preditiva.

3.4.4 Modelo *Light Gradient Boosting Machine* (LightGBM)

O *Light Gradient Boosting Machine* (LightGBM) é um algoritmo de aprendizado de máquina baseado em *gradient boosting* com árvores de decisão, no qual múltiplos modelos fracos são ajustados sequencialmente com o objetivo de reduzir progressivamente os erros de previsão. Nesse procedimento, cada nova árvore é estimada para corrigir os resíduos gerados nas iterações anteriores, o que permite ao modelo aprimorar de forma incremental sua capacidade preditiva. Como resultado, o algoritmo produz um preditor flexível, capaz de

capturar relações não lineares e interações complexas entre variáveis explicativas, características frequentemente observadas em séries macroeconômicas, como aquelas associadas à dinâmica inflacionária (Ke et al., 2017).

Uma característica central do *LightGBM* é sua elevada eficiência computacional e escalabilidade, decorrentes da incorporação de estratégias de otimização que tornam o processo de treinamento substancialmente mais rápido, sem comprometer o desempenho preditivo. Entre essas estratégias, destacam-se o uso de histogramas para a discretização dos atributos, reduzindo o custo computacional da busca por pontos de divisão, e o crescimento das árvores no formato *leaf-wise*, orientado pela maximização do ganho de informação e combinado a mecanismos de controle de complexidade que mitigam o risco de sobreajuste (Ke et al., 2017). Essas propriedades tornam o algoritmo particularmente adequado a aplicações empíricas com potenciais não linearidades, interações entre variáveis e necessidade de validação iterativa em bases temporais.

Além disso, diferentemente de modelos econométricos lineares tradicionais, o *LightGBM* apresenta a capacidade operacional de aprender padrões temporais diretamente a partir dos dados observados, permitindo identificar não linearidades, interações e heterogeneidades associadas ao processo inflacionário. Essa flexibilidade reduz a necessidade de impor hipóteses funcionais restritivas, como linearidade, homocedasticidade ou normalidade dos resíduos, frequentemente presentes em abordagens econométricas convencionais. Em economias emergentes, como a brasileira, marcadas por instabilidade macroeconômica, choques externos e mudanças estruturais, essa capacidade adaptativa do modelo pode representar uma vantagem significativa em exercícios de previsão.

Neste estudo, a estimação do *LightGBM* foi conduzida sob uma estratégia estritamente temporal, preservando-se a ordem cronológica das observações em todas as etapas de treino, validação e teste. Essa escolha foi adotada para evitar contaminação entre amostras e impedir o uso indevido de informações futuras no processo de aprendizagem. A separação entre treino e teste foi realizada por meio de um corte temporal previamente definido, no qual a amostra dentro do período de estimação (IS) correspondeu ao intervalo entre janeiro de 2004 e novembro de 2024, enquanto a avaliação fora da amostra (OOS) compreendeu o horizonte entre dezembro de 2024 e novembro de 2025. Adicionalmente, com o objetivo de assegurar a reprodutibilidade dos resultados, todo o experimento foi executado com uma única semente aleatória fixa (*random seed* = 42), aplicada à configuração geral do ambiente computacional e aos procedimentos de modelagem. Esse procedimento contribuiu para garantir consistência entre diferentes execuções, maior rastreabilidade das etapas empíricas e transparência

metodológica na comparação dos resultados obtidos.

A calibração dos hiperparâmetros foi realizada por meio da biblioteca *Optuna*, em combinação com a validação cruzada temporal do tipo *TimeSeriesSplit*. Diferentemente de procedimentos que particionam os dados aleatoriamente, essa estratégia utiliza divisões sequenciais da amostra, preservando a ordem cronológica das observações e reduzindo o risco de uso indevido de informações futuras no processo de estimação. Na especificação principal, adotaram-se cinco partições temporais ($n_splits = 5$), escolha que proporcionou equilíbrio adequado entre o tamanho relativo das janelas de treinamento e validação, além de maior estabilidade na avaliação do desempenho do modelo ao longo das diferentes rodadas de estimação.

A opção pelo *Optuna*, em lugar de uma busca exaustiva via *GridSearch*, deve-se à maior eficiência do procedimento de otimização bayesiana em espaços de busca contínuos e de maior dimensão. Enquanto o *GridSearch* exige a definição prévia de grades discretas e pode se tornar computacionalmente oneroso ou pouco eficiente, o *Optuna* permite explorar de forma mais flexível e informativa combinações promissoras de hiperparâmetros, concentrando o esforço computacional nas regiões do espaço com maior potencial de ganho preditivo. Nesse contexto, foram calibrados os principais hiperparâmetros ligados à taxa de aprendizado (*learning_rate*), à complexidade das árvores, especialmente ao número máximo de folhas (*num_leaves*) e à profundidade máxima (*max_depth*), ao número mínimo de observações por folha (*min_child_samples*), ao fracionamento de observações e variáveis por árvore (*subsample* e *colsample_bytree*), aos mecanismos de regularização penalizada L1 e L2 (*reg_alpha* e *reg_lambda*), além de parâmetros adicionais de controle estrutural, como o ganho mínimo para nova partição (*min_split_gain*) e o peso mínimo permitido em cada folha (*min_child_weight*).

Como análise complementar de robustez, também foram avaliadas configurações alternativas para o número de partições temporais, com três, cinco e sete *folds*. Esse exercício teve por objetivo verificar em que medida a escolha do número de partições temporais (n_splits) poderia influenciar a seleção dos hiperparâmetros, o desempenho preditivo estimado e as conclusões gerais do modelo. Os resultados mostraram que as conclusões qualitativas permaneceram estáveis entre as diferentes configurações, embora a especificação com cinco partições tenha sido mantida como referência principal por oferecer melhor equilíbrio entre tamanho das janelas, estabilidade dos resultados e comparabilidade do processo de otimização. Dessa forma, a configuração adotada na análise principal mostrou-se empiricamente consistente e metodologicamente adequada aos objetivos do estudo.

Após a seleção dos hiperparâmetros, a complexidade efetiva do modelo foi controlada

por meio do procedimento de *early stopping*, que interrompe o treinamento quando deixam de ocorrer ganhos relevantes de desempenho no conjunto de validação. Esse mecanismo permite determinar, de forma endógena, o número de iterações mais adequado, evitando crescimento excessivo da estrutura de árvores e reduzindo o risco de sobreajuste. Em seguida, realizou-se o procedimento de *refit* sobre o conjunto completo de treinamento, reaplicando os hiperparâmetros selecionados em uma nova estimação com toda a amostra disponível no período de treino.

A adoção do *refit* foi motivada pelo desenho empírico do estudo e pelos resultados obtidos nas etapas preliminares de estimação. Embora a estratégia baseada exclusivamente em *early stopping* tenha produzido desempenho preditivo consistente fora da amostra, observou-se que, no período de estimação, esse ajuste tendia a gerar previsões excessivamente suavizadas e menor aderência à dinâmica histórica da inflação. O *refit*, por sua vez, permitiu explorar de forma mais completa a informação disponível na amostra de treinamento, preservando a disciplina imposta pela etapa prévia de validação temporal e gerando ganhos significativos em termos de qualidade de ajuste dentro da amostra, redução das métricas de erro e melhor capacidade de reproduzir os movimentos observados da série inflacionária.

Ademais, o número final de árvores do modelo reestimado foi estabelecido com base na mediana do número ótimo de iterações observadas nos diferentes *folds* da validação cruzada temporal. Essa escolha decorre do fato de a mediana constituir medida robusta de tendência central, menos sensível a valores extremos associados a partições específicas da amostra. Com isso, evita-se que uma única janela temporal excepcionalmente favorável ou desfavorável determine, de forma desproporcional, a complexidade final do modelo. No presente estudo, esse procedimento conduziu à adoção de 405 iterações no *refit* final, resultando em uma especificação mais estável, parcimoniosa e coerente com o desempenho médio observado ao longo das diferentes janelas temporais de validação.

Em termos metodológicos, essa estratégia combina três objetivos complementares: preservar a coerência temporal do experimento, utilizar de forma eficiente toda a informação disponível no conjunto de treinamento e definir a complexidade final do modelo com base em critério robusto e estável. Desse modo, o modelo final resulta não de uma escolha arbitrária, mas de um procedimento sistemático de calibração, validação e reestimação, orientado pelo desempenho preditivo e pela estabilidade temporal.

Por fim, cumpre destacar que o *LightGBM* é utilizado neste estudo exclusivamente com finalidade preditiva, tendo como referência conceitual a Curva de Phillips Novo-Keynesiana Híbrida (CPNK-H) para orientar a seleção dos determinantes incluídos no modelo. Não se

pretende, portanto, estimar parâmetros estruturais da CPNK-H, mas empregar o algoritmo como instrumento empírico flexível para aprender, a partir dos dados, possíveis relações não lineares e dependências dinâmicas entre inflação, inflação passada, expectativas de inflação e hiato do produto. Consequentemente, a avaliação do modelo fundamenta-se em seu desempenho preditivo e na contribuição relativa das variáveis explicativas para as previsões geradas pelo algoritmo, interpretadas posteriormente por meio da metodologia SHAP (*SHapley Additive exPlanations*), não tendo por objetivo inferir relações causais estruturais entre os elementos considerados.

3.4.5 Critérios de avaliação e interpretabilidade do modelo

A avaliação do desempenho preditivo do modelo foi realizada com base em três métricas amplamente utilizadas na literatura de previsão de séries temporais: o Erro Médio Absoluto (MAE), a Raiz do Erro Quadrático Médio (RMSE) e o Erro Percentual Absoluto Médio Simétrico (SMAPE). Em conjunto, essas métricas permitem uma análise abrangente da acurácia das previsões, contemplando tanto medidas absolutas quanto relativas do erro e possibilitando uma avaliação mais robusta do desempenho preditivo.

Inicialmente, utiliza-se o Erro Médio Absoluto (MAE), métrica amplamente empregada na literatura de previsão de séries temporais, em razão de sua simplicidade conceitual e facilidade de interpretação. Essa medida corresponde à média das diferenças absolutas entre os valores observados e os valores previstos pelo modelo, sendo expressa nas mesmas unidades da variável analisada. Sua formulação é apresentada na Equação (8):

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (8)$$

em que y_i representa o valor observado no período i ; $\hat{y}_i$ corresponde ao valor previsto pelo modelo no mesmo período; e n indica o número total de observações consideradas na avaliação. Em termos analíticos, quanto menor o valor do MAE, maior tende a ser a proximidade média entre as previsões do modelo e os valores efetivamente observados, indicando maior acurácia preditiva.

De forma complementar, emprega-se a Raiz do Erro Quadrático Médio (RMSE), métrica que atribui maior penalização a erros de maior magnitude, uma vez que os desvios entre valores previstos e observados são elevados ao quadrado antes do cálculo da média. Essa

característica torna o RMSE particularmente útil em contextos nos quais grandes erros de previsão são indesejáveis, como na análise da inflação medida pelo Índice Nacional de Preços ao Consumidor Amplo (IPCA), em que desvios expressivos podem comprometer a qualidade das previsões econômicas. Formalmente, essa métrica é apresentada na Equação (9):

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (9)$$

em que y_i representa o valor observado no período i ; $\hat{y}_i$ corresponde ao valor previsto pelo modelo; e n indica o número total de observações utilizadas no cálculo da métrica. Embora o RMSE seja particularmente sensível a erros de maior magnitude, sua maior penalização de desvios elevados pode tornar a interpretação direta dos resultados menos intuitiva, sobretudo na presença de observações atípicas (*outliers*), que tendem a influenciar de forma desproporcional o valor da métrica.

Por fim, utiliza-se o Erro Percentual Absoluto Médio Simétrico (SMAPE), que, diferentemente do MAE e do RMSE, expressa o erro em termos relativos. Essa métrica calcula o desvio percentual médio entre valores previstos e observados, permitindo avaliar o desempenho do modelo de forma proporcional. Sua expressão matemática é apresentada na Equação (10):

$$\text{SMAPE} = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{(|y_i| + |\hat{y}_i|)/2} \quad (10)$$

em que y_i representa o valor observado no período i ; $\hat{y}_i$ corresponde ao valor previsto pelo modelo; e n indica o número total de observações. O SMAPE apresenta vantagens em relação ao Erro Percentual Absoluto Médio (MAPE), sobretudo por reduzir problemas associados a divisões por valores muito próximos de zero e por apresentar maior estabilidade em séries nas quais os valores observados assumem magnitudes relativamente baixas, características frequentemente observadas em séries inflacionárias.

Além da avaliação da acurácia preditiva, este estudo emprega a metodologia SHAP (*SHapley Additive exPlanations*) para analisar a contribuição das variáveis explicativas nas previsões geradas pelo modelo *LightGBM*. Fundamentada na teoria dos jogos cooperativos proposta por Shapley (1952) e posteriormente adaptada para modelos de aprendizado de

máquina por Lundberg e Lee (2017), essa abordagem permite decompor cada previsão individual em contribuições marginais atribuídas a cada variável explicativa. Esse procedimento assegura propriedades desejáveis do ponto de vista interpretativo, como acurácia local, consistência e transparência na atribuição das contribuições de cada variável para o resultado preditivo do modelo.

No caso específico de modelos baseados em árvores de decisão, como o *LightGBM*, a estimação dos valores SHAP é realizada por meio do método *Tree SHAP*, que permite o cálculo eficiente e exato dessas contribuições, preservando as propriedades teóricas da decomposição proposta. A partir da agregação das explicações locais ao longo da amostra, torna-se possível avaliar a relevância preditiva média das variáveis centrais associadas à Curva de Phillips Novo-Keynesiana Híbrida — inflação passada, expectativas de inflação e hiato do produto — na formação das previsões de inflação corrente, favorecendo uma interpretação mais estruturada do papel relativo de cada determinante na dinâmica inflacionária.

Nesse sentido, a utilização do SHAP amplia a análise estritamente preditiva ao possibilitar a investigação da coerência empírica entre os padrões aprendidos pelo algoritmo e os mecanismos teóricos sugeridos pela CPNK-H. Assim, o procedimento adotado contribui para ampliar a transparência e a interpretabilidade do modelo, atenuando o caráter de “caixa-preta” frequentemente associado a algoritmos de aprendizado de máquina, sem implicar, contudo, qualquer interpretação causal das relações observadas. Adicionalmente, essa abordagem permite também aproximar a análise empírica dos fundamentos teóricos, ao evidenciar como os determinantes inflacionários são incorporados pelo modelo no processo de previsão.

Como etapa complementar à estratégia metodológica, este estudo também incorpora análises exploratórias das variáveis econômicas utilizadas na modelagem preditiva da inflação brasileira. Embora o modelo *LightGBM* não imponha pressupostos clássicos frequentemente associados à econometria de séries temporais, como a estacionariedade das variáveis, tais análises contribuem para uma compreensão mais abrangente da dinâmica temporal dos dados e para a documentação de propriedades empíricas relevantes das séries observadas. Para esse fim, são consideradas estatísticas descritivas, inspeção gráfica das séries temporais e testes formais de estacionariedade, cujos resultados são apresentados no Apêndice B desta dissertação.

Com base na estratégia metodológica delineada, a seção seguinte apresenta os resultados empíricos deste estudo, discutindo o desempenho preditivo do modelo *LightGBM*, bem como a interpretação econômica das previsões por meio da metodologia SHAP e a aderência dos resultados aos fundamentos teóricos da Curva de Phillips Novo-Keynesiana Híbrida.

3.5 RESULTADOS E DISCUSSÃO

Esta seção apresenta e discute os principais resultados empíricos obtidos a partir da aplicação do modelo *LightGBM* à previsão da inflação brasileira no contexto da Curva de Phillips Novo-Keynesiana Híbrida. Inicialmente, avalia-se o desempenho preditivo do modelo com base nas métricas definidas na seção metodológica, complementadas por evidências gráficas que permitem examinar sua capacidade de reproduzir a dinâmica observada da inflação dentro e fora da amostra. Em seguida, os resultados são analisados sob uma perspectiva econômica por meio da técnica SHAP, a qual possibilita investigar a contribuição marginal das variáveis explicativas para as previsões geradas pelo modelo. Por fim, os achados são discutidos à luz da literatura especializada, com o objetivo de avaliar sua coerência com os mecanismos teóricos da Curva de Phillips Novo-Keynesiana Híbrida e destacar suas principais implicações empíricas.

3.5.1 Desempenho preditivo do modelo *LightGBM*

A avaliação do desempenho preditivo do modelo *LightGBM* abrange o período dentro da amostra (*in-sample*), de janeiro de 2004 a novembro de 2024, e o horizonte de previsão fora da amostra (*out-of-sample*), de dezembro de 2024 a novembro de 2025. A distinção entre esses dois intervalos permite examinar, simultaneamente, a capacidade do modelo de reproduzir a dinâmica histórica da inflação e seu desempenho em um horizonte prospectivo.

Com base nessa estrutura de estimação, a análise adota uma perspectiva estritamente preditiva, fundamentada em métricas quantitativas de erro amplamente utilizadas na literatura especializada, bem como em evidências gráficas que permitem comparar a trajetória observada da inflação com os valores ajustados e previstos pelo modelo ao longo do tempo. Nesse sentido, a Tabela 3.1 sintetiza o desempenho preditivo do *LightGBM* nos períodos dentro e fora da amostra.

Tabela 3.1 – Desempenho preditivo do modelo *LightGBM* na previsão da inflação mensal brasileira (2004–2025).

Amostra	MAE	RMSE	SMAPE (%)
IS (jan. 2004–nov. 2024)	0,1817	0,2435	47,4328
OOS (dez. 2024–nov. 2025)	0,2691	0,3661	69,5164

Fonte: Elaborado pelo autor, a partir dos resultados estimados do modelo *LightGBM*.
Nota: IS (*in-sample*) refere-se ao período utilizado para estimação e ajuste do modelo, enquanto OOS (*out-of-sample*) corresponde ao horizonte reservado exclusivamente à avaliação preditiva fora da amostra.


Os resultados apresentados na Tabela 3.1 evidenciam que o modelo apresenta bom ajuste no período dentro da amostra, com MAE de 0,1817 ponto percentual, RMSE de 0,2435 ponto percentual e SMAPE de 47,4328%. Esses valores indicam capacidade consistente de reproduzir a trajetória histórica da inflação mensal brasileira, tanto em sua dinâmica média quanto em parte relevante de sua variabilidade. Em termos empíricos, isso sugere que o algoritmo captou de forma adequada os padrões predominantes presentes na amostra de estimação, incluindo componentes de persistência inflacionária, influência das expectativas e oscilações associadas às condições cíclicas da economia.

No período fora da amostra, como esperado em exercícios prospectivos aplicados a séries macroeconômicas, observa-se deterioração do desempenho preditivo, com MAE de 0,2691 ponto percentual, RMSE de 0,3661 ponto percentual e SMAPE de 69,5164%, refletindo a maior incerteza associada às previsões futuras. Esse comportamento é compatível com a complexidade inerente à previsão da inflação em horizonte prospectivo, especialmente em ambientes sujeitos a choques recorrentes, mudanças nas condições macroeconômicas, oscilações de preços relativos e episódios de maior volatilidade, como a economia brasileira. Em termos econômicos, a elevação dos erros fora da amostra sugere que parte relevante da dinâmica inflacionária nesse período esteve associada a fatores conjunturais e perturbações de difícil antecipação, o que naturalmente reduz a precisão preditiva mesmo em modelos adequadamente especificados.

Ainda assim, a magnitude dos erros permanece compatível com a complexidade do problema analisado, o que sugere que o modelo preserva utilidade preditiva mesmo diante da perda esperada de precisão no horizonte prospectivo. Em síntese, os resultados indicam um modelo com forte aderência histórica e capacidade preditiva consistente no período de teste, ainda que com menor precisão em relação à amostra de estimação.

A evidência gráfica apresentada na Figura 3.1 reforça essa interpretação ao evidenciar a aderência do modelo à trajetória observada da inflação ao longo do tempo. No período de ajuste dentro da amostra, observa-se elevada proximidade entre as séries ajustada e observada, indicando que o modelo acompanha de forma consistente a dinâmica inflacionária e seus movimentos de curto prazo. Ao longo de parte relevante da amostra, especialmente entre 2006 e 2014, a inflação mensal apresenta oscilações relativamente moderadas, compatíveis com ambientes de maior estabilidade macroeconômica, condução monetária mais previsível e expectativas inflacionárias relativamente ancoradas. Nesses intervalos, a aderência entre valores observados e ajustados tende a ser mais elevada, refletindo maior regularidade dos padrões econômicos capturados pelo algoritmo.

Figura 3.1 – Ajuste amostral e previsão da inflação no Brasil pelo modelo *LightGBM* no período de 2004 a 2025.



Fonte: Elaborado pelo autor, a partir dos resultados estimados do modelo *LightGBM*.

Nota: A área sombreada corresponde ao intervalo de predição de 95%, representando a incerteza associada às projeções.

Em contraste, o gráfico também evidencia períodos marcados por volatilidade mais intensa e movimentos abruptos da inflação. Entre 2014 e 2016, observam-se elevações expressivas e maior dispersão da série, contexto possivelmente associado à deterioração fiscal, à desvalorização cambial, à recomposição de preços administrados e ao aumento da incerteza política no período que antecedeu e sucedeu o processo de *impeachment* presidencial no Brasil. Posteriormente, entre 2020 e 2022, nota-se novo aumento da instabilidade, compatível com os efeitos econômicos da pandemia de Covid-19, desorganização de cadeias produtivas globais, choques sobre preços de alimentos e energia, oscilações cambiais e posterior processo de reabertura econômica. Em episódios dessa natureza, a inflação torna-se mais sensível a choques exógenos e mudanças rápidas de preços relativos, o que naturalmente amplia a complexidade do exercício preditivo.


Já no período fora da amostra, a comparação entre inflação observada e prevista revela alguns episódios de maior afastamento entre previsão e realização, embora as projeções permaneçam, em termos gerais, na mesma ordem de grandeza dos valores observados. Esse resultado sugere que, mesmo diante de um ambiente prospectivo sujeito a novas perturbações e mudanças conjunturais, o modelo preserva capacidade de captar a tendência predominante da inflação brasileira. Adicionalmente, o intervalo de predição de 95% fornece uma medida explícita da incerteza associada às previsões, de modo que bandas mais amplas sinalizam maior

variabilidade esperada e menor precisão em determinados meses do horizonte prospectivo, contribuindo para uma interpretação mais prudente e informativa dos resultados projetados.

Em síntese, a Figura 3.1 indica que o *LightGBM* reproduz com consistência os períodos de maior estabilidade inflacionária e também responde, ainda que com maior dificuldade, aos episódios de ruptura e elevada volatilidade macroeconômica. Tal evidência é coerente com a natureza da inflação brasileira no período analisado, marcada pela alternância entre fases de relativa estabilidade e momentos de choques relevantes, reforçando a utilidade do modelo como instrumento empírico de previsão e análise econômica.

Em complemento à avaliação agregada do desempenho preditivo apresentada na Figura 3.1, a análise gráfica da inflação observada e prevista no horizonte fora da amostra permite inspeção mais detalhada do comportamento temporal das projeções do modelo. Essa abordagem possibilita examinar, mês a mês, o grau de aderência das previsões do *LightGBM* à trajetória realizada da inflação, bem como identificar desvios pontuais associados a períodos de maior incerteza ou volatilidade inflacionária, conforme ilustrado na Figura 3.2.

Figura 3.2 – Inflação observada e prevista pelo modelo *LightGBM* no período fora da amostra (dez. 2024–nov. 2025).



Fonte: Elaborado pelo autor, a partir dos resultados estimados do modelo *LightGBM*.

Nota: A área sombreada corresponde ao intervalo de predição de 95%, representando a incerteza associada às projeções.

A partir dessa evidência gráfica, observa-se que o modelo acompanha, de modo geral, a trajetória da inflação observada ao longo de grande parte do horizonte prospectivo, reproduzindo sua tendência predominante. Em vários meses do período analisado, especialmente nos intervalos de menor volatilidade, a série observada apresenta comportamento

relativamente estável, condição em que as previsões tendem a mostrar maior aderência aos valores realizados. Contudo, surgem desvios mais expressivos em meses nos quais a inflação realizada apresentou movimentos mais atípicos. Em fevereiro de 2025, por exemplo, verifica-se forte aceleração da inflação mensal, acima do valor previsto pelo modelo, possivelmente relacionada a reajustes sazonais concentrados no início do ano letivo, recomposição de preços administrados e pressões de demanda em segmentos de serviços. Já em agosto de 2025, observa-se variação negativa da inflação mensal, comportamento menos antecipado pelo modelo e potencialmente associado a recuos pontuais nos preços de alimentos, combustíveis ou outros itens de maior volatilidade, além de efeitos temporários de base de comparação.

Nesses episódios, os erros assumem magnitude mais elevada, o que é coerente com o aumento do RMSE fora da amostra, métrica particularmente sensível a discrepâncias acentuadas entre valores previstos e observados. Ainda assim, as previsões permanecem, em termos agregados, dentro de uma faixa plausível, enquanto os intervalos de predição capturam de forma consistente a maior incerteza associada ao período analisado, fornecendo uma medida adicional de prudência na interpretação dos resultados projetados. Esse comportamento sugere que o modelo é capaz de captar a tendência subjacente da inflação mensal brasileira de forma adequada, ainda que apresente limitações naturais para antecipar choques de curto prazo, mudanças abruptas de preços relativos e oscilações transitórias fora da amostra.

Em síntese, a evidência gráfica reforça os resultados quantitativos discutidos nesta subseção ao indicar que o modelo *LightGBM* combina forte aderência aos dados históricos com desempenho preditivo moderadamente robusto fora da amostra, ainda que acompanhado por perda de precisão no horizonte prospectivo. Cabe ressaltar que esses achados não devem ser interpretados como limitação específica do algoritmo, mas como uma manifestação natural das dificuldades estruturais inerentes à previsão da inflação em cenários macroeconômicos voláteis. Diante desses achados, a subseção seguinte aprofunda a análise ao interpretar economicamente a estrutura preditiva aprendida pelo modelo por meio da metodologia SHAP.

3.5.2 Interpretação econômica dos resultados via SHAP

A análise apresentada nesta etapa tem como objetivo interpretar economicamente os resultados do modelo *LightGBM* por meio da técnica SHAP (*SHapley Additive exPlanations*), avaliando em que medida os padrões aprendidos pelo algoritmo são coerentes com os fundamentos teóricos da dinâmica inflacionária. Diferentemente da avaliação preditiva, centrada no desempenho agregado das previsões, a abordagem baseada em SHAP permite

decompor cada previsão em contribuições marginais associadas às variáveis explicativas, ampliando a transparência do processo preditivo e aproximando os resultados empíricos dos mecanismos teóricos da Curva de Phillips Novo-Keynesiana Híbrida. Nessa perspectiva, os valores SHAP devem ser interpretados como medidas de contribuição para a previsão gerada pelo modelo, e não como evidência de relações causais entre as variáveis e a inflação observada.

A Tabela 3.2 apresenta a importância global das variáveis explicativas com base na média do valor absoluto dos valores SHAP calculados sobre a amostra de treinamento.

Tabela 3.2 – Importância global das variáveis explicativas do modelo *LightGBM* na previsão da inflação mensal brasileira, segundo valores SHAP médios absolutos.

Ordem	Variável	Média do valor absoluto SHAP
1	Inflação passada (π_{t-1})	0,1023
2	Expectativas de inflação ($E_t[\pi_{t+1}]$)	0,0934
3	Hiato do produto (x_{t-1})	0,0226

Fonte: Elaborado pelo autor, a partir dos resultados estimados do modelo *LightGBM*.


Nota: A medida corresponde à média, ao longo da amostra de treinamento, do valor absoluto dos valores SHAP. Valores mais elevados indicam maior contribuição média, em magnitude, da variável para o desvio da predição em relação ao valor esperado do modelo.

Os resultados da Tabela 3.2 indicam que a inflação passada (π_{t-1}) e as expectativas de inflação ($E_t[\pi_{t+1}]$) concentram a maior parte da relevância preditiva do modelo, com magnitudes médias elevadas e relativamente próximas entre si. Esse resultado sugere que o *LightGBM* atribuiu peso significativo tanto ao componente inercial da inflação quanto ao componente prospectivo associado às expectativas dos agentes econômicos, padrão compatível com a literatura especializada sobre a dinâmica inflacionária brasileira e com a formulação da Curva de Phillips Novo-Keynesiana Híbrida aplicada ao contexto nacional.

Em linha com essa evidência, a elevada magnitude média das contribuições associadas à inflação passada e às expectativas de inflação indica que o algoritmo capturou dois mecanismos centrais do processo inflacionário brasileiro: a persistência inflacionária, frequentemente relacionada a rigidezes nominais e mecanismos de indexação, e o papel das expectativas dos agentes na formação de preços, reforçando a relevância desses canais para a dinâmica da inflação e para a transmissão da política monetária. Em contraste, o hiato do produto defasado (x_{t-1}) apresenta contribuição média substancialmente inferior, sugerindo que as condições cíclicas da economia exerceram papel complementar, e não dominante, na explicação preditiva da inflação no período analisado. Em termos econômicos, isso indica que, embora a atividade econômica contenha informação relevante, sua capacidade explicativa incremental foi menor do que a observada para os determinantes nominais e vinculados às expectativas inflacionárias.

Tal resultado é coerente com parte da evidência empírica para a economia brasileira, que frequentemente aponta menor sensibilidade da inflação às medidas de atividade econômica quando comparada à influência das expectativas e da inércia inflacionária, especialmente em contextos marcados por elevada volatilidade macroeconômica e recorrência de choques de oferta e de custos. Desse modo, os achados reforçam a plausibilidade econômica da estrutura aprendida pelo algoritmo e ampliam a interpretabilidade empírica do modelo. A partir dessa evidência agregada, a análise é aprofundada por meio da distribuição dos valores SHAP ao longo da amostra, o que permite examinar não apenas a magnitude média das contribuições, mas também sua dispersão e heterogeneidade entre as observações, conforme apresentado na Figura 3.3.

Figura 3.3 – Distribuição dos valores SHAP das variáveis explicativas do modelo *LightGBM* aplicado à previsão da inflação mensal brasileira (2004–2025).



Fonte: Elaborado pelo autor, a partir dos resultados estimados do modelo *LightGBM*.

Nota: Cada ponto representa a contribuição marginal de uma observação para a previsão do modelo. Valores SHAP positivos elevam a previsão da inflação, enquanto valores negativos a reduzem. A escala de cores indica o valor observado de cada variável, do menor (azul) ao maior (rosa).

A Figura 3.3 amplia a interpretação dos resultados ao evidenciar não apenas a importância média das variáveis explicativas na previsão da inflação brasileira, mas também a distribuição de seus efeitos marginais ao longo da amostra. Observa-se que valores mais elevados da inflação passada (π_{t-1}) e das expectativas de inflação ($E_t[\pi_{t+1}]$) tendem, em geral, a estar associados a contribuições positivas para a previsão do modelo, enquanto valores mais

baixos dessas variáveis se relacionam a contribuições negativas. Esse padrão é economicamente coerente com a dinâmica inflacionária subjacente ao modelo, pois valores mais elevados dessas variáveis tendem a contribuir para previsões mais altas de inflação, ao passo que valores mais baixos tendem a contribuir para previsões mais reduzidas.

Além disso, a dispersão dos pontos em torno de diferentes níveis de contribuição sugere que os efeitos das variáveis explicativas não são uniformes ao longo da amostra, indicando a presença de heterogeneidade nas contribuições preditivas. Em termos práticos, isso significa que o impacto de uma mesma variável sobre a previsão do modelo pode variar conforme o contexto macroeconômico, o nível da própria variável ou sua associação com os demais determinantes da inflação. Essa evidência indica que o *LightGBM* capturou padrões preditivos mais complexos e sensíveis ao contexto, o que amplia a capacidade interpretativa do modelo em comparação com especificações lineares mais restritivas. Em particular, observa-se maior amplitude dos valores SHAP associados à inflação passada e às expectativas de inflação, reforçando a posição central dessas variáveis na estrutura preditiva aprendida pelo modelo.

Por sua vez, o hiato do produto (x_{t-1}) apresenta valores SHAP mais concentrados em torno de zero e menor dispersão relativa, o que sinaliza contribuição preditiva mais limitada no período analisado. Isso não implica irrelevância econômica da atividade, mas sugere que, na amostra considerada, os componentes inercial e prospectivo da inflação exerceram influência superior às condições cíclicas da economia na previsão da inflação. Assim, a leitura conjunta da Tabela 3.2 e da Figura 3.3 indica que o modelo não apenas atribuiu maior importância média à inflação passada e às expectativas de inflação, mas também concentrou nessas variáveis a maior variação das contribuições individuais ao longo da amostra, reforçando sua centralidade na estrutura preditiva da inflação brasileira.

Em síntese, a evidência obtida por meio da metodologia SHAP indica que o modelo *LightGBM* aprendeu padrões preditivos economicamente plausíveis e consistentes com a literatura especializada. Ao atribuir maior relevância justamente às variáveis centrais da Curva de Phillips Novo-Keynesiana Híbrida, o modelo evidencia o potencial de abordagens baseadas em aprendizado de máquina para a previsão de séries macroeconômicas, preservando, ao mesmo tempo, consistência teórica, interpretabilidade e transparência analítica. Cabe ressaltar, no entanto, que essas evidências devem ser compreendidas estritamente no plano preditivo, no qual os valores SHAP tornam mais transparente a forma como o modelo organiza a informação disponível para produzir suas previsões e mensuram as contribuições marginais de cada variável para esse processo, sem que disso decorra, por si só, uma interpretação causal das relações estimadas. A partir desses resultados, a subseção seguinte discute suas implicações para a

dinâmica inflacionária à luz do referencial teórico adotado.

3.5.3 Discussão dos resultados à luz da Curva de Phillips Novo-Keynesiana Híbrida

Os resultados apresentados nas subseções anteriores indicam que o modelo *LightGBM*, orientado pela Curva de Phillips Novo-Keynesiana Híbrida (CPNK-H), alcança desempenho preditivo consistente e, simultaneamente, aprende padrões alinhados aos principais mecanismos macroeconômicos associados à dinâmica inflacionária brasileira. Em particular, a interpretação baseada na técnica SHAP aponta maior relevância preditiva da inflação passada e das expectativas de inflação na composição das previsões, enquanto o hiato do produto apresenta contribuição média substancialmente menor. Esse conjunto de evidências é coerente com a adequação empírica de uma formulação híbrida da Curva de Phillips Novo-Keynesiana para o Brasil, na qual coexistem componentes retrospectivos e prospectivos em sua determinação, com papel relativamente mais limitado das condições cíclicas da economia na explicação preditiva da inflação.

Do ponto de vista teórico, a proeminência da inflação passada é compatível com a presença de mecanismos de inércia inflacionária e rigidez nominal, frequentemente associados a práticas de indexação, contratos e reajustes baseados em informações defasadas. Ao mesmo tempo, a elevada relevância atribuída às expectativas de inflação sugere que o modelo capturou de forma consistente a dimensão prospectiva do processo inflacionário, reforçando o papel da ancoragem das expectativas dos agentes econômicos como elemento central da dinâmica de preços e da transmissão da política monetária.

Em consonância com o referencial teórico adotado neste trabalho, a literatura empírica aplicada ao Brasil documenta de forma recorrente a importância conjunta das expectativas inflacionárias e da inflação passada em modelos híbridos da Curva de Phillips Novo-Keynesiana. Estudos como Muinhos e Alves (2003), Alves (2011), Leal (2014) e Machado e Portugal (2014) indicam que a incorporação das expectativas de inflação — usualmente extraídas de pesquisas de mercado — tende a melhorar o desempenho empírico dos modelos em comparação a especificações baseadas exclusivamente em componentes retrospectivos. Ao mesmo tempo, o componente inercial permanece relevante, ainda que sua magnitude varie conforme o período analisado, a *proxy* adotada e o método de estimação empregado. Em contraste, esses trabalhos também indicam que a contribuição da atividade econômica, representada pelo hiato do produto, tende a ser menos robusta e mais sensível à especificação, sugerindo que, no contexto brasileiro, seu papel na dinâmica inflacionária é relativamente mais

limitado quando comparado aos mecanismos associados às expectativas e à inércia inflacionária.

Nesse contexto, a menor relevância preditiva atribuída ao hiato do produto nas explicações SHAP mostra-se consistente com evidências recorrentes para a economia brasileira. Embora o hiato do produto ocupe papel central no arcabouço Novo-Keynesiano, como *proxy* do custo marginal real, diversos estudos apontam coeficientes pouco robustos para medidas de atividade econômica, frequentemente influenciados por choques de oferta, variações cambiais, mudanças institucionais e mecanismos de indexação. Esses fatores tendem a enfraquecer o canal demanda–preços em determinadas janelas amostrais, tornando o papel da atividade econômica mais complementar do que dominante na dinâmica inflacionária.

Do ponto de vista metodológico, as evidências apresentadas reforçam que abordagens de aprendizado de máquina podem contribuir de forma substantiva para a previsão macroeconômica, sem abdicar da disciplina teórica associada aos modelos estruturais. Ao orientar a seleção das variáveis explicativas pela Curva de Phillips Novo-Keynesiana Híbrida e empregar a técnica SHAP para interpretação econômica dos resultados, o estudo evidencia a capacidade do modelo *LightGBM* de conciliar flexibilidade estatística, transparência analítica e coerência econômica, característica particularmente relevante em séries macroeconômicas sujeitas a choques recorrentes e instabilidade estrutural, como no caso da economia brasileira.

Por fim, cabe ressaltar que as atribuições SHAP devem ser interpretadas como medidas de relevância preditiva, e não como evidência de relações causais entre as variáveis observadas. Os valores SHAP expressam a contribuição marginal das variáveis para o desvio da previsão em relação ao valor esperado do modelo, sendo calculados de forma condicionada às características observadas nos dados e à estrutura do modelo estimado. Assim, ainda que os padrões aprendidos se mostrem coerentes com a teoria econômica, a interpretação apropriada permanece restrita ao domínio preditivo e comparativo, não estrutural.

Em síntese, os resultados obtidos indicam que o modelo *LightGBM* apresenta desempenho preditivo consistente e aprende um padrão de atribuições coerente com a evidência macroeconômica para o Brasil, no qual as expectativas de inflação e a inércia inflacionária desempenham papel central na explicação da dinâmica dos preços, enquanto a atividade econômica, representada pelo hiato do produto, exerce função complementar. Esses achados fornecem base empírica sólida para a aplicação de métodos de aprendizado de máquina como complemento às abordagens econométricas tradicionais, ao evidenciar que modelos mais flexíveis e capazes de incorporar não linearidades e interações complexas entre variáveis, quando orientados por um arcabouço teórico consistente e interpretados por técnicas como o

SHAP, podem ampliar a capacidade preditiva e analítica dos estudos inflacionários sem comprometer o rigor econômico análises realizadas. Com base nessas evidências, a seção seguinte apresenta as considerações finais do estudo, destacando os principais achados, suas implicações e limitações, bem como possíveis direções para pesquisas futuras.

3.6 CONSIDERAÇÕES FINAIS

Este artigo avaliou a capacidade preditiva de um modelo multivariado aplicado à inflação brasileira, estruturado a partir da Curva de Phillips Novo-Keynesiana Híbrida (CPNK-H) e estimado por meio do algoritmo de aprendizado de máquina *LightGBM*. A análise empírica utilizou dados mensais no período de janeiro de 2004 a novembro de 2024 para a etapa de estimação, com projeções realizadas entre dezembro de 2024 e novembro de 2025, permitindo uma avaliação rigorosa do desempenho preditivo do modelo em horizonte fora da amostra. Ao combinar fundamentos macroeconômicos consolidados na literatura com uma abordagem flexível de aprendizado de máquina, o estudo contribui para o debate contemporâneo sobre a previsão da inflação em economias emergentes — em especial a brasileira — frequentemente caracterizadas por instabilidade estrutural, choques macroeconômicos recorrentes e mecanismos de persistência inflacionária, fatores que dificultam a manutenção de relações lineares estáveis ao longo do tempo.

Os resultados obtidos indicam que o modelo *LightGBM* apresenta desempenho preditivo consistente tanto dentro quanto fora da amostra, com a elevação esperada dos erros no horizonte prospectivo, refletindo a maior incerteza inerente à previsão macroeconômica. A evidência gráfica apresentada na Figura 3.1 reforça esse resultado ao indicar que o modelo reproduz de forma adequada a trajetória da inflação ao longo do tempo, ainda que, como é característico em exercícios de previsão, ocorram desvios pontuais em períodos marcados por oscilações inflacionárias mais intensas. Em conjunto, essas evidências sugerem que a estratégia metodológica adotada — baseada em validação temporal, controle de complexidade por meio de *early stopping* durante o treinamento do modelo e reestimação final via procedimento de *refit*, com seleção sistemática de hiperparâmetros — contribui para um equilíbrio adequado entre aderência aos dados históricos e capacidade de generalização das previsões fora da amostra.

Além do desempenho preditivo evidenciado, o estudo avançou ao incorporar uma dimensão sistemática de interpretabilidade por meio da técnica SHAP. A decomposição das previsões indica que a inflação passada e as expectativas de inflação concentram a maior

relevância preditiva média, enquanto o hiato do produto exerce papel relativamente menor na composição das previsões do modelo. Esse padrão é compatível com a formulação híbrida da Curva de Phillips Novo-Keynesiana e com evidências empíricas recorrentes para a economia brasileira, segundo as quais mecanismos de inércia inflacionária e formação de expectativas explicam parcela substancial da dinâmica de preços, ao passo que medidas de atividade econômica frequentemente apresentam menor robustez empírica e maior sensibilidade à *proxy* adotada. Nesse sentido, a interpretação baseada em SHAP sugere que o algoritmo aprendeu regularidades preditivas economicamente plausíveis e teoricamente coerentes, contribuindo para reduzir a opacidade frequentemente associada a modelos de aprendizado de máquina.

Do ponto de vista metodológico, os achados desta pesquisa reforçam a viabilidade de empregar técnicas modernas de previsão sem abdicar da disciplina teórica própria da macroeconomia. Ao utilizar a Curva de Phillips Novo-Keynesiana Híbrida como referencial para a seleção das variáveis explicativas e ao interpretar as previsões em termos de contribuições preditivas dos determinantes do modelo, o estudo evidencia que algoritmos de aprendizado de máquina podem ampliar de forma substancial a capacidade preditiva e, simultaneamente, preservar grau adequado de transparência analítica, conciliando flexibilidade estatística com coerência econômica e interpretabilidade dos resultados. Essa combinação mostra-se particularmente relevante em aplicações voltadas à política econômica, nas quais previsões acuradas e interpretáveis são desejáveis tanto para fins de comunicação quanto para o monitoramento de riscos inflacionários e a avaliação de cenários em ambientes de elevada incerteza e mudanças conjunturais recorrentes.

Contudo, algumas limitações identificadas no desenvolvimento deste ensaio devem ser reconhecidas. Em particular, a medida do hiato do produto, construída a partir do IBC-Br com a aplicação do filtro de Hodrick–Prescott em modo *one-sided*, está sujeita a incertezas inerentes aos métodos de extração de tendência em tempo real, bem como às limitações associadas à mensuração da atividade econômica. Ademais, determinantes macroeconômicos potencialmente relevantes para a dinâmica inflacionária brasileira — como a taxa de câmbio, os preços de *commodities* e a taxa básica de juros (Selic) — não foram explicitamente incorporados à especificação do modelo, o que pode restringir sua capacidade de antecipar movimentos inflacionários em contextos dominados por choques específicos não capturados pelas variáveis centrais da CPNK-H.

À luz dessas limitações, algumas extensões naturais se apresentam para pesquisas futuras. Nesse sentido, recomenda-se, inicialmente, a exploração de medidas alternativas de atividade econômica e de custo marginal, como indicadores de utilização da capacidade

instalada, hiatos estimados por filtros alternativos ou modelos em espaço de estados, além de *proxies* vinculadas ao mercado de trabalho. Sugere-se, ainda, a incorporação explícita de variáveis adicionais potencialmente relevantes para a inflação brasileira, como a taxa de câmbio, os preços de *commodities* e indicadores de condições financeiras. Por fim, a comparação ampliada com *benchmarks* econométricos e preditivos permitiria quantificar de forma mais direta o ganho incremental do *LightGBM* em relação a abordagens tradicionalmente utilizadas na previsão macroeconômica.

Em síntese, o estudo indica que a previsão da inflação no Brasil pode se beneficiar de uma estratégia que combine: (i) disciplina teórica na seleção de variáveis explicativas; (ii) flexibilidade estatística para capturar não linearidades e interações complexas entre variáveis; e (iii) interpretabilidade para avaliar a coerência econômica dos padrões aprendidos pelo modelo. Ao fornecer evidências de desempenho preditivo consistente e de alinhamento entre os padrões aprendidos pelo algoritmo e os mecanismos enfatizados pela literatura da Curva de Phillips Novo-Keynesiana Híbrida, a pesquisa reforça o potencial do uso criterioso de métodos de aprendizado de máquina na previsão de séries temporais macroeconômicas, contribuindo para o aprimoramento de ferramentas analíticas relevantes ao debate econômico, ao monitoramento conjuntural e à formulação mais eficiente de políticas públicas.

REFERÊNCIAS

- ALVES, Felipe Alduino. **A curva de Phillips Novo-Keynesiana brasileira**. 2011. Trabalho de Conclusão de Curso (Graduação em Ciências Econômicas) – Insper Instituto de Ensino e Pesquisa, São Paulo, 2011. Disponível em: <https://repositorio-api.insper.edu.br/server/api/core/bitstreams/e966d969-5f8f-472b-af8b-d0d58f2f31c7/content>. Acesso em: 20 jul. 2025.
- BANCO CENTRAL DO BRASIL. **Medidas de hiato do produto no Brasil**. Relatório de Inflação, jun. 2024. Brasília, DF: Banco Central do Brasil, 2024. Disponível em: <https://www.bcb.gov.br/content/ri/relatorioinflacao/202406/ri202406b10p.pdf>. Acesso em: 20 dez. 2025.
- BARBOSA, Fernando de Holanda. **Macroeconomia**. Rio de Janeiro: FGV Editora, 2017.
- BARNICHON, Régis; MESTERS, Geert. Identifying modern macro equations with old shocks. **The Quarterly Journal of Economics**, v. 135, n. 4, p. 2255–2298, 2020. Disponível em: <https://doi.org/10.1093/qje/qjaa022>. Acesso em: 10 jul. 2025.
- BLANCHARD, Olivier. **Macroeconomia**. 5. ed. São Paulo: Pearson Prentice Hall, 2011.
- CALVO, Guillermo A. Staggered prices in a utility-maximizing framework. **Journal of Monetary Economics**, v. 12, n. 3, p. 383–398, 1983. Disponível em: [https://doi.org/10.1016/0304-3932\(83\)90060-0](https://doi.org/10.1016/0304-3932(83)90060-0). Acesso em: 15 jul. 2025.
- CLARIDA, Richard; GALI, Jordi; GERTLER, Mark. The science of monetary policy: a new Keynesian perspective. **Journal of Economic Literature**, v. 37, n. 4, p. 1661–1707, 1999. Disponível em: <https://www.aeaweb.org/articles?id=10.1257/jel.37.4.1661>. Acesso em: 20 jun. 2025.
- COSTA, Evanderson Mateus Santos. **Curva de Phillips Novo-Keynesiana: histórico e estimação**. 2014. Monografia (Graduação em Ciências Econômicas) – Universidade de Brasília, Brasília, 2014. Disponível em: https://bdm.unb.br/bitstream/10483/10127/1/2014_EvandersonMateusSantosCosta.pdf. Acesso em: 13 ago. 2025.
- FRIEDMAN, Milton. The role of monetary policy. **The American Economic Review**, v. 58, n. 1, p. 1–17, 1968. Disponível em: https://public.econ.duke.edu/~kdh9/Courses/Graduate%20Macro%20History/Readings-1/Friedman_Role%20of%20Monetary%20Policy.pdf. Acesso em: 15 out. 2025.
- GALÍ, Jordi. **Monetary policy, inflation, and the business cycle: an introduction to the New Keynesian framework and its applications**. 2. ed. Princeton: Princeton University Press, 2015. Disponível em: https://perhuaman.wordpress.com/wp-content/uploads/2014/06/gali_polc3adtica_monetaria.pdf. Acesso em: 15 ago. 2025.
- GALÍ, Jordi; GERTLER, Mark. **Inflation dynamics: a structural econometric analysis**. Cambridge: National Bureau of Economic Research, 2000. (NBER Working Paper, n. 7551). Disponível em: <http://www.nber.org/papers/w7551>. Acesso em: 23 jul. 2025.

HODRICK, Robert J.; PRESCOTT, Edward C. Postwar U.S. business cycles: an empirical investigation. **Journal of Money, Credit and Banking**, v. 29, n. 1, p. 1–16, 1997. Disponível em: <https://www.jstor.org/stable/2953682>. Acesso em: 2 jun. 2025.

KE, Guolin et al. LightGBM: a highly efficient gradient boosting decision tree. In: CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS, 31., 2017, Long Beach, CA. Disponível em: https://proceedings.neurips.cc/paper_files/paper/2017/file/6449f44a102fde848669bdd9eb6b76fa-Paper.pdf. Acesso em: 28 jun. 2025.

LEAL, Guilherme Strifezzi. **Estimativa da curva de Phillips para a economia brasileira**. 2014. Monografia (Graduação em Ciências Econômicas) – Insper Instituto de Ensino e Pesquisa, São Paulo, 2014. Disponível em: <https://repositorio.insper.edu.br/entities/publication/5f003320-3244-4c6e-b6d5-e2d2bc2a99a9>. Acesso em: 28 jul. 2025.

LUCAS JR., Robert E. Econometric policy evaluation: a critique. **Carnegie-Rochester Conference Series on Public Policy**, v. 1, p. 19–46, 1976. Disponível em: https://people.sabanciuniv.edu/atilgan/FE500_Fall2013/2Nov2013_CevdetAkay/LucasCritique_1976.pdf. Acesso em: 17 out. 2025.

LUNDBERG, Scott M.; LEE, Su-In. A unified approach to interpreting model predictions. **Advances in Neural Information Processing Systems**, v. 30, p. 4765–4774, 2017. Disponível em: <https://arxiv.org/abs/1705.07874>. Acesso em: 28 ago. 2025.

MACHADO, Vicente da Gama; PORTUGAL, Marcelo Savino. **Phillips curve in Brazil: an unobserved components approach**. Brasília, DF: Banco Central do Brasil, 2014. (Working Paper Series, n. 354). Disponível em: <https://www.bcb.gov.br/pec/wps/ingl/wps354.pdf>. Acesso em: 21 jul. 2025.

MANKIW, N. Gregory. **Princípios de economia**. 7. ed. São Paulo: Cengage Learning, 2019.

MENDES, Igor Manoel Bezerra Roque. **Curva de Phillips Novo-Keynesiana no Brasil: uma nova abordagem econométrica**. 2021. Trabalho de Conclusão de Curso (Bacharelado em Ciências Econômicas) – Universidade Federal da Paraíba, João Pessoa, 2021. Disponível em: <https://repositorio.ufpb.br/jspui/bitstream/123456789/22038/1/IMBRM07022022.pdf>. Acesso em: 5 jul. 2025.

MICROSOFT CORPORATION. **LightGBM documentation**. Disponível em: <https://lightgbm.readthedocs.io/en/stable/>. Acesso em: 16 jan. 2025.

MUINHOS, Marcelo Kfoury; ALVES, Sérgio Afonso Lago. **Medium size macroeconomic model for the Brazilian economy**. Brasília, DF: Banco Central do Brasil, 2003. (Working Paper Series, n. 64). Disponível em: <https://www.bcb.gov.br/content/publicacoes/WorkingPaperSeries/wps64.pdf>. Acesso em: 12 jul. 2025.

PHELPS, Edmund S. Phillips curves, expectations of inflation and optimal unemployment over time. **Economica**, New Series, v. 34, n. 135, p. 254–281, 1967. Disponível em: <https://www.jstor.org/stable/2552025>. Acesso em: 14 jun. 2025.

PHILLIPS, A. W. The relation between unemployment and the rate of change of money wage rates in the United Kingdom, 1861–1957. **Economica**, v. 25, n. 100, p. 283–299, 1958. Disponível em: <https://doi.org/10.1111/j.1468-0335.1958.tb00003.x>. Acesso em: 18 ago. 2025.

SAMUELSON, Paul A.; SOLOW, Robert M. Analytical aspects of anti-inflation policy. **The American Economic Review**, v. 50, n. 2, p. 177–194, 1960. Disponível em: https://elearning.unito.it/sme/pluginfile.php/192712/course/section/41483/SamSol_AER60.pdf. Acesso em: 21 jul. 2025.

SCANDOLARA, Renata; BOURSCHEIDT, Deise; NUNES, Paulo Alexandre. **Curva de Phillips no Brasil: uma revisão sobre a sua aplicabilidade**. In: SEMINÁRIO DE JOVENS PESQUISADORES EM ECONOMIA E DESENVOLVIMENTO, 3., [2014?], Santa Maria, RS. Disponível em: <https://www.ufsm.br/app/uploads/sites/533/2019/05/Curva-de-Phillips-no-Brasil-uma-revisao-sobre-a-sua-aplicabilidade.pdf>. Acesso em: 13 jul. 2025.

SCHWARTZMAN, Felipe Farah. Estimativa de Curva de Phillips para o Brasil com preços desagregados. **Economia Aplicada**, v. 10, n. 1, p. 137–155, 2006. Disponível em: <https://doi.org/10.1590/S1413-80502006000100008>. Acesso em: 12 jul. 2025.

SHAPLEY, Lloyd S. A value for n-person games. In: KUHN, H. W.; TUCKER, A. W. (ed.). **Contributions to the theory of games II**. Princeton: Princeton University Press, 1952. Disponível em: <https://www.rand.org/content/dam/rand/pubs/papers/2021/P295.pdf>. Acesso em: 29 ago. 2025.

4 CONCLUSÃO

Esta dissertação teve como objetivo central investigar a previsão da inflação no Brasil no período de 2000 a 2025, combinando abordagens econométricas tradicionais, técnicas de aprendizado de máquina e fundamentos teóricos da macroeconomia. A estratégia empírica foi estruturada em dois ensaios complementares, permitindo examinar, de forma progressiva, tanto o desempenho preditivo de modelos univariados quanto os ganhos analíticos decorrentes da incorporação de fundamentos econômicos em um ambiente multivariado.

No primeiro ensaio, a análise concentrou-se na comparação do desempenho preditivo entre os modelos ARIMA, *Prophet* e *LightGBM* na previsão da inflação brasileira, utilizando a série mensal do Índice de Preços ao Consumidor Amplo (IPCA). Os resultados evidenciaram que, embora modelos tradicionais como o ARIMA mantenham relevância em contextos de maior estabilidade econômica, em razão de características como parcimônia, transparência e interpretabilidade, técnicas mais flexíveis de aprendizado de máquina tendem a apresentar vantagens em cenários marcados por maior complexidade dinâmica, como os observados na economia brasileira ao longo do período analisado.

Em particular, o modelo *LightGBM* apresentou o melhor desempenho preditivo entre os métodos avaliados, registrando os menores valores de MAE (0,0920), RMSE (0,1680) e SMAPE (23,93%). Esse resultado reforça sua capacidade de capturar não linearidades e de se adaptar a mudanças no comportamento inflacionário. Do ponto de vista gráfico, o modelo também demonstrou elevada aderência à trajetória observada da inflação, acompanhando com maior proximidade oscilações de curto prazo e episódios de maior volatilidade. Embora as previsões fora da amostra apresentem comportamento mais suavizado ao final do horizonte projetado, sua capacidade de reproduzir com maior precisão picos e inflexões reforça o potencial do *LightGBM* como ferramenta robusta para a modelagem de séries econômicas sujeitas a choques recorrentes e instabilidade estrutural.

O modelo ARIMA(1,0,0), por sua vez, apresentou desempenho consistente em períodos de maior estabilidade econômica e menor volatilidade da inflação, particularmente após a forte aceleração inflacionária observada em 2003 e em intervalos relativamente mais regulares, como 2004–2007 e parte de 2009–2013. Nessas janelas, a dinâmica inflacionária mostrou-se mais previsível e mais fortemente influenciada por sua própria trajetória passada, favorecendo o uso de uma modelagem linear baseada em componentes autorregressivos. Em termos quantitativos, o ARIMA(1,0,0) apresentou desempenho intermediário, inferior ao *LightGBM*, porém superior ao *Prophet* em parte das métricas avaliadas, o que reforça sua utilidade preditiva em contextos

de menor instabilidade macroeconômica e dinâmica inflacionária mais regular.

Já o modelo *Prophet* destacou-se menos por sua acurácia preditiva e mais por sua capacidade de decomposição interpretável da série temporal em componentes de tendência e sazonalidade. Os resultados evidenciaram tendência global suavemente decrescente no período analisado, além de padrões sazonais relativamente regulares ao longo da amostra, o que amplia o conteúdo analítico do modelo e favorece seu uso em aplicações nas quais a transparência da decomposição temporal seja relevante aos objetivos da pesquisa. Apesar disso, o *Prophet* apresentou os maiores erros entre os modelos avaliados no período dentro da amostra (MAE de 0,2456, RMSE de 0,3412 e SMAPE de 53,40%), sinalizando menor capacidade de adaptação preditiva a dinâmicas inflacionárias mais complexas e voláteis. Ainda assim, sua flexibilidade na modelagem de tendência e sazonalidade, aliada à facilidade de atualização das previsões, preserva sua utilidade em aplicações que exigem projeções frequentes e interpretação transparente dos componentes temporais da série.

Em conjunto, os resultados apresentados no primeiro ensaio reforçam a ideia de que não existe um modelo universalmente superior para a previsão da inflação, mas que o desempenho relativo das abordagens depende principalmente das características do ambiente econômico e do objetivo analítico da aplicação. Dessa forma, modelos mais estruturados tendem a oferecer maior transparência e facilidade de interpretação, ao passo que abordagens baseadas em aprendizado de máquina se mostram mais eficazes na captura de dinâmicas complexas e na obtenção de melhor desempenho preditivo, especialmente em contextos marcados por choques e mudanças estruturais, como os observados na economia brasileira.

No segundo ensaio, a análise avançou para uma abordagem multivariada fundamentada na Curva de Phillips Novo-Keynesiana Híbrida, incorporando variáveis centrais da literatura macroeconômica — inflação defasada, expectativas de inflação e hiato do produto — em uma estrutura preditiva baseada em aprendizado de máquina. A utilização do modelo *LightGBM*, selecionado a partir de seu melhor desempenho no primeiro ensaio, permitiu combinar flexibilidade preditiva com fundamentos teóricos consolidados na literatura macroeconômica. Além disso, a incorporação do método SHAP possibilitou examinar a contribuição relativa dos determinantes do modelo no processo de previsão, ampliando a transparência analítica e a coerência econômica dos resultados.

Os achados do segundo ensaio indicaram desempenho preditivo consistente do modelo *LightGBM* dentro e fora da amostra, ao mesmo tempo em que evidenciaram a predominância das expectativas de inflação e da inércia inflacionária como determinantes centrais da dinâmica dos preços no Brasil, enquanto o hiato do produto exerceu papel complementar. Esses

resultados dialogam diretamente com a literatura empírica aplicada ao país e reforçam a interpretação de que a inflação brasileira apresenta natureza híbrida, combinando elementos retrospectivos e prospectivos em seu processo de formação.

A articulação entre os dois ensaios constitui um dos principais diferenciais desta dissertação. Enquanto o primeiro ensaio estabeleceu uma base comparativa ao avaliar o desempenho relativo de diferentes metodologias em um ambiente univariado, o segundo aprofundou a análise ao incorporar fundamentos econômicos explícitos, deslocando o foco da mera acurácia preditiva para a compreensão dos mecanismos subjacentes à inflação brasileira. Essa transição evidencia que a previsão econômica não deve ser avaliada exclusivamente pela minimização de erros estatísticos de predição, mas também por sua coerência com a teoria econômica e por sua capacidade de gerar interpretações consistentes dos fenômenos analisados.

Nesse contexto, um resultado particularmente relevante — e que merece explicitação mais cuidadosa — refere-se à diferença de desempenho observada entre o *LightGBM* no ambiente univariado, no primeiro ensaio, e no ambiente multivariado, no segundo. Embora fosse plausível esperar que a incorporação de variáveis macroeconômicas ampliasse a capacidade preditiva do modelo, os resultados indicaram desempenho relativamente superior do *LightGBM* univariado em termos de acurácia preditiva fora da amostra.

Essa evidência pode ser compreendida a partir de três aspectos principais. Em primeiro lugar, a própria natureza da inflação brasileira, marcada por elevada persistência temporal, implica que parte substancial da informação relevante para previsões de curto prazo já se encontra incorporada à trajetória passada da própria série. Em segundo lugar, a inclusão de variáveis teoricamente relevantes amplia a complexidade do espaço de estimação e pode introduzir ruído adicional, sobretudo quando tais variáveis estão sujeitas a erros de mensuração, revisões ou defasagens informacionais, como ocorre com expectativas de inflação e medidas de hiato do produto. Em terceiro lugar, há um *trade-off* inerente entre flexibilidade estatística e disciplina teórica: enquanto o modelo univariado explora de forma mais direta os padrões empíricos da série, o multivariado impõe uma estrutura orientada por fundamentos macroeconômicos, o que enriquece a interpretação econômica, mas pode reduzir a eficiência preditiva em determinados horizontes de curto prazo.

Assim, o desempenho relativamente inferior do modelo multivariado em termos de erro de previsão não deve ser interpretado como fragilidade metodológica, mas como reflexo de uma escolha analítica que privilegia, simultaneamente, interpretação econômica e coerência teórica. Dessa forma, os resultados sugerem que a incorporação de fundamentos macroeconômicos não garante, por si só, ganhos em acurácia preditiva, especialmente em horizontes mais curtos.

Ainda assim, ela amplia de forma significativa o conteúdo analítico das previsões, ao permitir compreender os mecanismos que orientam a dinâmica inflacionária, aspecto particularmente relevante para aplicações em política econômica.

A principal contribuição desta dissertação reside, portanto, na integração entre desempenho preditivo e coerência teórica, ao articular métodos modernos de previsão com fundamentos macroeconômicos consolidados na literatura. Nessa perspectiva, ao combinar modelos econométricos tradicionais, técnicas de aprendizado de máquina e fundamentos macroeconômicos consolidados na literatura, o trabalho demonstra que a evolução metodológica observada não implica a substituição dos modelos clássicos, mas sua complementação por abordagens mais flexíveis e capazes de capturar a complexidade dos dados econômicos contemporâneos. Nesse sentido, os resultados evidenciam que métodos de aprendizado de máquina, quando ancorados em fundamentos econômicos consistentes e acompanhados de ferramentas de interpretabilidade, podem ampliar simultaneamente a acurácia das previsões e o conteúdo analítico das projeções inflacionárias.

Essa contribuição manifesta-se, de forma complementar, nos planos metodológico, analítico e prático desta pesquisa. Do ponto de vista metodológico, a dissertação demonstra a aplicabilidade de técnicas modernas de modelagem a um problema clássico da macroeconomia, evidenciando os ganhos associados à utilização de validação temporal, otimização de hiperparâmetros e análise de interpretabilidade na previsão da inflação. Em termos analíticos, o estudo reforça a relevância da Curva de Phillips Novo-Keynesiana como estrutura de referência para a compreensão da inflação, mesmo quando combinada a algoritmos de aprendizado de máquina, mostrando que a inovação metodológica pode ser incorporada sem ruptura com os fundamentos teóricos que organizam a interpretação econômica. Sob a perspectiva prática, os resultados oferecem subsídios relevantes para a formulação de política monetária e para a análise de cenários macroeconômicos, ao indicar que previsões mais acuradas podem ser obtidas sem abrir mão da coerência econômica, ampliando a utilidade dessas ferramentas tanto para a análise acadêmica quanto para aplicações voltadas ao monitoramento inflacionário e ao apoio à tomada de decisão.

Adicionalmente, os resultados dialogam de forma direta com a literatura empírica sobre inflação no Brasil, ao reforçar a relevância das expectativas e da inércia inflacionária como determinantes centrais da dinâmica dos preços, ao mesmo tempo em que reconhecem o papel complementar das condições de atividade econômica na formação inflacionária. Essa evidência é consistente com a interpretação de que a inflação brasileira apresenta natureza híbrida, combinando componentes retrospectivos e prospectivos em seu processo de determinação.

Apesar das contribuições apresentadas neste estudo, algumas limitações identificadas devem ser reconhecidas. Em primeiro lugar, a análise concentrou-se em um conjunto específico de modelos e variáveis, o que, embora adequado aos objetivos propostos, não esgota o conjunto de abordagens possíveis na literatura de previsão inflacionária. Em segundo lugar, embora tenham sido adotados cuidados metodológicos relevantes, como validação fora da amostra e controle de complexidade dos modelos, a natureza dinâmica da economia implica que o desempenho preditivo pode variar ao longo do tempo, especialmente na presença de novos choques estruturais. Ademais, a mensuração do hiato do produto, ainda que realizada com técnicas amplamente utilizadas na literatura, permanece sujeita a incertezas inerentes ao método de estimação, o que pode afetar parcialmente os resultados do modelo multivariado.

Diante dessas limitações, abrem-se possibilidades relevantes para pesquisas futuras. Entre elas, destacam-se a incorporação de novas variáveis explicativas, como taxa de câmbio, preços de *commodities* e indicadores financeiros; a utilização de modelos híbridos que combinem explicitamente estruturas econométricas e algoritmos de aprendizado de máquina; a exploração de técnicas mais avançadas de modelagem, como redes neurais profundas; e a ampliação da análise para diferentes horizontes de previsão. Essas estratégias complementares podem contribuir para o aprimoramento da capacidade preditiva e para o avanço da modelagem empírica da inflação, especialmente em ambientes caracterizados por instabilidade estrutural e elevada complexidade dinâmica, como o da economia brasileira.

Em síntese, esta dissertação contribui para o debate contemporâneo sobre previsão da inflação ao demonstrar que o avanço metodológico mais promissor não reside na simples substituição dos modelos preditivos tradicionais por técnicas de aprendizado de máquina, mas na construção de abordagens integradas, capazes de combinar rigor econométrico, flexibilidade algorítmica e consistência teórica. Ao evidenciar essa complementaridade, o trabalho reforça a relevância de uma perspectiva interdisciplinar na análise macroeconômica, em que a inovação metodológica se associa à preservação dos fundamentos que orientam a interpretação dos fenômenos econômicos. Nesse contexto, a integração entre modelos econométricos tradicionais e métodos de aprendizado de máquina revela elevado potencial para o avanço da previsão de séries macroeconômicas, ao combinar capacidade explicativa, ganhos de acurácia preditiva e maior flexibilidade analítica, contribuindo para o aperfeiçoamento das ferramentas de apoio à política econômica e para o fortalecimento da estabilidade macroeconômica, com efeitos positivos sobre o poder de compra e o bem-estar da população.

APÊNDICE A – AVALIAÇÃO PREDITIVA FORA DA AMOSTRA DOS MODELOS DO PRIMEIRO ENSAIO

Os apêndices desta dissertação reúnem análises empíricas complementares que não integram o corpo principal dos ensaios, mas que contribuem para o aprofundamento e a robustez dos resultados apresentados. Em particular, parte dessas análises foi desenvolvida após a finalização e a submissão do primeiro ensaio, em razão da indisponibilidade, à época, dos dados do IPCA realizado para o período fora da amostra considerado. Com a posterior divulgação dessas informações, tornou-se possível ampliar a avaliação preditiva dos modelos estimados no primeiro ensaio, bem como incorporar testes estatísticos adicionais sugeridos *ex post* durante a apresentação do trabalho em evento científico. Ressalta-se que tais extensões não alteram os resultados centrais nem as conclusões dos ensaios, tendo caráter estritamente complementar e documental, sendo apresentadas com o objetivo de assegurar transparência, rigor metodológico e completude analítica da dissertação.

A.1 CONTEXTUALIZAÇÃO DA AVALIAÇÃO FORA DA AMOSTRA


A análise fora da amostra (*out-of-sample*) desempenha papel central em estudos de previsão econômica, pois permite avaliar a capacidade dos modelos em generalizar os padrões identificados no período de estimação para horizontes futuros não observados (Hyndman; Athanasopoulos, 2018). Tal abordagem mostra-se particularmente relevante em contextos caracterizados por elevada volatilidade macroeconômica e pela ocorrência de possíveis mudanças estruturais, como no regime inflacionário recente da economia brasileira, nos quais modelos bem ajustados ao passado podem apresentar desempenho limitado quando confrontados com novas informações. Nesse sentido, a comparação sistemática das previsões com os valores efetivamente observados, aliada ao uso de métricas de erro fora da amostra, constitui prática consolidada na literatura de previsão econômica e de séries temporais, sendo amplamente recomendada tanto em abordagens econométricas tradicionais quanto em métodos baseados em aprendizado de máquina (Hyndman; Koehler, 2006; Ke et al., 2017).

A.2 COMPARAÇÃO VISUAL ENTRE AS PREVISÕES E A INFLAÇÃO OBSERVADA

A Figura A.1 apresenta a comparação visual entre a inflação observada, medida pelo IPCA, e as trajetórias previstas pelos modelos ARIMA, *Prophet* e *LightGBM* no período fora

da amostra. A análise gráfica permite identificar diferenças relevantes na dinâmica das previsões realizadas no primeiro ensaio, especialmente no que se refere à capacidade de cada modelo em acompanhar oscilações de curto prazo e episódios de maior volatilidade inflacionária.

Figura A.1 – Comparação entre a inflação observada e as previsões fora da amostra dos modelos ARIMA(1,0,0), *Prophet* e *LightGBM* (dez. 2024–nov. 2025).



Fonte: Elaborado pelo autor, a partir de dados do Banco Central do Brasil (BCB) e resultados dos modelos ARIMA(1,0,0), *Prophet* e *LightGBM* estimados em suas versões otimizadas.

De modo geral, observa-se que os modelos exibem comportamentos preditivos distintos. O ARIMA(1,0,0) tende a gerar previsões mais suavizadas, refletindo sua estrutura estritamente autorregressiva. O *Prophet*, por sua vez, incorpora de forma mais flexível padrões sazonais e ajustes de tendência ao longo do tempo. Já o modelo *LightGBM* apresenta um comportamento preditivo mais estável ao longo do horizonte fora da amostra, com previsões concentradas em torno de valores próximos à média histórica da inflação mensal. Embora essa característica contribua para a redução dos erros médios, observa-se uma menor sensibilidade do modelo a oscilações mais abruptas do IPCA observado, resultando em discrepâncias pontuais em meses marcados por choques inflacionários positivos ou negativos. Esse padrão sugere a presença de um efeito de regressão à média, típico de modelos de aprendizado de máquina treinados para minimizar perdas globais, especialmente em amostras fora da amostra de dimensão reduzida.

A.3 MÉTRICAS DE DESEMPENHO FORA DA AMOSTRA

A avaliação do desempenho preditivo foi conduzida com base nos valores mensais

realizados da inflação para a economia brasileira no período de dezembro de 2024 a novembro de 2025. Para isso, foram calculadas, para cada um dos modelos analisados — ARIMA(1,0,0), *Prophet* e *LightGBM* —, as métricas de erro MAE (*Mean Absolute Error*), RMSE (*Root Mean Squared Error*) e SMAPE (*Symmetric Mean Absolute Percentage Error*), com o objetivo de mensurar a acurácia das previsões em um horizonte prospectivo.

Tabela A.1 – Desempenho fora da amostra dos modelos na previsão da inflação brasileira (dez. 2024–nov. 2025).

Modelo	MAE	RMSE	SMAPE (%)
<i>Prophet</i>	0,2067	0,2726	66,57
<i>LightGBM</i>	0,2500	0,3377	66,91
ARIMA(1,0,0)	0,2875	0,3680	72,37

Fonte: Elaborado pelo autor, a partir de resultados dos modelos ARIMA(1,0,0), *Prophet* e *LightGBM* estimados em suas versões otimizadas.

Os resultados apresentados na Tabela A.1 indicam que o modelo *Prophet* obteve o melhor desempenho preditivo no horizonte analisado, ao registrar os menores valores de erro em todas as métricas consideradas, seguido pelo modelo *LightGBM*. Em contraste, o modelo ARIMA(1,0,0) apresentou desempenho relativamente inferior, com maiores erros médios de previsão. Em termos descritivos, esses resultados sugerem que abordagens mais flexíveis, baseadas em decomposição estrutural e em técnicas de aprendizado de máquina, podem oferecer melhor adaptação às oscilações da série inflacionária no período considerado. Ainda assim, essas diferenças devem ser interpretadas com cautela, especialmente em razão da curta extensão da amostra de avaliação, o que reforça a conveniência de complementar a análise por meio de testes estatísticos formais de comparação de previsões, apresentados na seção subsequente.

A.4 TESTE DE DIEBOLD–MARIANO: FUNDAMENTAÇÃO E RESULTADOS

O Teste de Diebold–Mariano (DM) é amplamente utilizado na literatura de previsão para avaliar se duas séries de previsões concorrentes apresentam diferenças estatisticamente significativas em termos de acurácia preditiva. Formalmente, o procedimento compara o desempenho médio de dois modelos por meio da diferença entre funções de perda aplicadas aos respectivos erros de previsão, testando a hipótese nula de que a diferença média dessas perdas é estatisticamente igual a zero (Diebold; Mariano, 1995). Neste apêndice, o teste DM foi aplicado às previsões fora da amostra, considerando o período de dezembro de 2024 a novembro

de 2025, com base na função de perda quadrática aplicada aos erros de previsão, permitindo comparações pareadas entre os modelos ARIMA, *Prophet* e *LightGBM*.

Tabela A.2 – Teste de Diebold–Mariano (DM) para comparação da acurácia preditiva fora da amostra dos modelos (dez. 2024–nov. 2025).

Comparação	Estatística DM	p-valor
ARIMA(1,0,0) vs <i>Prophet</i>	1,652	0,127
ARIMA(1,0,0) vs <i>LightGBM</i>	1,936	0,079
<i>Prophet</i> vs <i>LightGBM</i>	-1,117	0,288

Fonte: Elaborado pelo autor, a partir de resultados dos modelos ARIMA(1,0,0), *Prophet* e *LightGBM* estimados em suas versões otimizadas.

Os resultados apresentados na Tabela A.2 indicam que, no horizonte fora da amostra analisado, nenhuma das comparações rejeita a hipótese nula de igualdade de acurácia preditiva ao nível de significância de 5%. Em particular, as comparações entre ARIMA(1,0,0) e *Prophet*, assim como entre *Prophet* e *LightGBM*, apresentam p-valores superiores a esse limiar, não se verificando evidência de superioridade preditiva estatisticamente significativa entre esses modelos.

No entanto, ao se adotar um nível de significância de 10%, observa-se que a comparação entre ARIMA(1,0,0) e *LightGBM* apresenta evidência marginal de diferença de desempenho preditivo (p-valor = 0,079). Nesse caso, o sinal positivo da estatística DM indica que o modelo *LightGBM* apresenta menor erro médio de previsão em relação ao ARIMA(1,0,0), sugerindo desempenho preditivo superior sob um critério menos restritivo.

Ainda assim, esse resultado deve ser interpretado com cautela, sobretudo em razão da curta extensão do período *out-of-sample* analisado, o que tende a reduzir o poder estatístico do teste e limitar a detecção de diferenças significativas entre os modelos. Ademais, a não rejeição da hipótese nula de igualdade de acurácia preditiva ao nível de significância de 5% sugere que as diferenças observadas podem decorrer de variações amostrais, não sendo possível afirmar, de forma conclusiva, a existência de superioridade preditiva consistente entre os modelos.

Por fim, a inexistência de diferenças estatisticamente significativas entre *Prophet* e *LightGBM*, bem como entre ARIMA(1,0,0) e *Prophet*, indica que, no horizonte considerado, os modelos apresentam desempenho preditivo comparável sob critérios estritos de inferência estatística. Ainda assim, a evidência marginal favorável ao *LightGBM*, aliada à sua fundamentação teórica e à sua capacidade de capturar relações não lineares e dinâmicas, reforça a adequação de sua utilização no segundo ensaio desta dissertação, no contexto da modelagem baseada na Curva de Phillips Novo-Keynesiana Híbrida.

A.5 SÍNTESE E IMPLICAÇÕES COMPLEMENTARES

De forma geral, as análises apresentadas neste apêndice ampliam e aprofundam a avaliação preditiva dos modelos considerados no primeiro ensaio, ao incorporar informações que não estavam disponíveis no momento de sua finalização. A comparação fora da amostra, a análise das métricas de erro e a aplicação de testes estatísticos adicionais indicam que, embora existam diferenças numéricas no desempenho médio entre os modelos $ARIMA(1,0,0)$, *Prophet* e *LightGBM*, tais distinções não se mostram estatisticamente significativas no horizonte analisado. Esse resultado decorre, em grande medida, da curta extensão do período fora da amostra e da elevada volatilidade observada na inflação brasileira no intervalo considerado.

Nesse sentido, as evidências aqui apresentadas não modificam as conclusões centrais dos ensaios desta dissertação, mas contribuem para uma interpretação mais cautelosa e abrangente do desempenho preditivo dos modelos. Em particular, esses resultados reforçam a importância da adoção de critérios complementares na escolha de métodos de previsão da inflação, tais como estabilidade das projeções, consistência preditiva e aderência aos objetivos analíticos de cada ensaio. Ademais, o conjunto de evidências reunido neste apêndice fornece suporte adicional à utilização do *LightGBM* no segundo ensaio, ao mesmo tempo em que assegura transparência metodológica, rigor empírico e completude analítica ao trabalho como um todo.

APÊNDICE B – ANÁLISE EXPLORATÓRIA DAS SÉRIES ECONÔMICAS UTILIZADAS NO SEGUNDO ENSAIO

Este apêndice reúne análises exploratórias complementares das séries utilizadas no segundo ensaio, com o objetivo de documentar suas propriedades empíricas básicas e ampliar a transparência analítica ao processo de modelagem. As evidências aqui apresentadas não constituem pressupostos formais para a estimação do modelo *Light Gradient Boosting Machine* (*LightGBM*), mas auxiliam na compreensão do comportamento temporal das variáveis econômicas empregadas no estudo.

B.1 ESTATÍSTICAS DESCRITIVAS DAS SÉRIES ECONÔMICAS DO MODELO

Como etapa inicial da análise exploratória, a Tabela B.1 apresenta as estatísticas descritivas das séries econômicas utilizadas no segundo ensaio, abrangendo o período de janeiro de 2004 a novembro de 2024. Essas estatísticas sintetizam aspectos centrais da distribuição — como tendência central, dispersão, assimetria e amplitude — e fornecem uma visão geral do comportamento das variáveis incorporadas ao modelo preditivo. Ressalta-se que tais análises possuem caráter estritamente exploratório e não constituem pressupostos para a estimação do modelo *LightGBM*, conforme discutido na seção metodológica.

Tabela B.1 – Estatísticas descritivas das séries do modelo do segundo ensaio (2004–2024).

Estatística	π_t	π_{t-1}	$E_t[\pi_{t+1}]$	x_{t-1}
Número de observações	247	247	247	247
Média	0,46	0,46	0,40	-0,21
Desvio-padrão	0,33	0,33	0,16	2,69
Mínimo	-0,68	-0,68	-0,09	-13,04
Percentil 25	0,25	0,25	0,30	-1,39
Mediana	0,44	0,44	0,39	0,44
Percentil 75	0,62	0,62	0,49	1,70
Máximo	1,62	1,62	0,91	4,42
Assimetria	0,23	0,23	0,41	-1,15

Fonte: Elaborado pelo autor, a partir de dados do Banco Central do Brasil (BCB).

Nota: π_t representa a inflação corrente (IPCA); π_{t-1} a inflação defasada em um período; $E_t[\pi_{t+1}]$ a expectativa de inflação; e x_{t-1} o hiato do produto defasado, obtido via filtro de Hodrick–Prescott em modo *one-sided*.


A Tabela B.1 evidencia diferenças relevantes entre as séries em termos de escala, variabilidade e assimetria. A inflação corrente (π_t) e sua primeira defasagem (π_{t-1}) apresentam estatísticas praticamente idênticas — média de 0,46% ao mês, desvio-padrão de 0,33, mediana de 0,44 e intervalo entre -0,68 e 1,62 — o que é esperado, uma vez que se trata da mesma

variável deslocada no tempo. As expectativas de inflação ($E_t[\pi_{t+1}]$) exibem menor dispersão (desvio-padrão de 0,16) e menor amplitude ($-0,09$ a $0,91$), sugerindo um componente mais suavizado e menos volátil do que a inflação observada, em consonância com a natureza agregada da mediana da Pesquisa Focus. O hiato do produto defasado (x_{t-1}), por sua vez, apresenta elevada variabilidade (desvio-padrão de 2,69) e amplitude acentuada ($-13,04$ a $4,42$), com assimetria negativa ($-1,15$), indicando uma distribuição com cauda à esquerda e a ocorrência de fases recessivas mais pronunciadas do que os episódios de expansão. Em conjunto, essas evidências apontam para um comportamento heterogêneo das variáveis analisadas, o que reforça a pertinência do uso de um modelo preditivo flexível, capaz de capturar relações complexas e padrões dinâmicos distintos entre as séries observadas.

B.2 ANÁLISE GRÁFICA DA EVOLUÇÃO TEMPORAL DAS VARIÁVEIS ECONÔMICAS

Esta subseção complementa as estatísticas descritivas apresentadas na Tabela B.1 ao permitir uma avaliação qualitativa dos comportamentos das séries utilizadas ao longo do período analisado, de janeiro de 2004 a novembro de 2024. A inspeção visual das séries permite identificar padrões de persistência, volatilidade, movimentos conjuntos e episódios extremos, contribuindo para a compreensão de suas propriedades temporais e para a avaliação de sua adequação ao exercício de previsão da inflação.

Figura B.1 – Evolução temporal das séries do modelo do segundo ensaio (2004–2024).



Fonte: Elaborado pelo autor, a partir de dados do Banco Central do Brasil (BCB).

Nota: A figura apresenta a inflação corrente (π_t), a inflação defasada (π_{t-1}), as expectativas de inflação ($E_t[\pi_{t+1}]$) e o hiato do produto defasado (x_{t-1}), construído a partir do IBC-Br por meio do filtro de Hodrick–Prescott em modo *one-sided*. O painel (a) exibe as séries em unidades originais, enquanto o painel (b) mostra as mesmas séries padronizadas pelo método z-score, permitindo a comparação de suas dinâmicas relativas.

A Figura B.1 ilustra a trajetória temporal da inflação corrente (π_t), da inflação defasada

(π_{t-1}), das expectativas de inflação ($E_t[\pi_{t+1}]$) e do hiato do produto defasado (x_{t-1}), tanto em unidades originais quanto em versões padronizadas. Observa-se elevada proximidade entre a inflação corrente e sua defasagem, refletindo a persistência inflacionária característica da economia brasileira ao longo do período analisado. As expectativas de inflação apresentam trajetória mais suave e menor volatilidade relativa, coerente com o processo de formação baseado na mediana da Pesquisa Focus e com o papel estabilizador das expectativas no regime de metas de inflação. Em contraste, o hiato do produto exibe comportamento mais volátil e assimétrico, com desvios negativos acentuados associados a períodos de desaceleração econômica, destacando-se episódios como a crise financeira internacional iniciada em 2008 e o choque provocado pela pandemia da COVID-19. A padronização das séries evidencia diferenças relevantes de escala e variabilidade entre os componentes do modelo, bem como a presença de regimes distintos ao longo do tempo, reforçando a ocorrência de não linearidades e mudanças no padrão dinâmico das relações macroeconômicas. Em conjunto, a análise gráfica corrobora as evidências das estatísticas descritivas e sustenta a adoção de uma abordagem preditiva flexível, como o modelo *LightGBM* utilizado neste estudo.

B.3 TESTES DE ESTACIONARIEDADE DAS SÉRIES (PHILLIPS–PERRON)

Complementarmente, são apresentados os resultados dos testes de raiz unitária de Phillips–Perron (PP) aplicados às séries econômicas do segundo ensaio, com o propósito de documentar suas propriedades de estacionariedade ao longo da amostra analisada. O teste de Phillips–Perron foi adotado por sua robustez à presença de heterocedasticidade e autocorrelação serial nos resíduos, características frequentemente observadas em séries macroeconômicas mensais.

Os testes foram conduzidos considerando a inclusão de constante (especificação do tipo *c*) e um número máximo de 20 defasagens, de modo a capturar adequadamente a dinâmica serial das séries. A hipótese nula do teste corresponde à presença de raiz unitária (não-estacionária), sendo rejeitada quando o valor-*p* é inferior ao nível de significância adotado neste estudo, fixado em 5%.

Tabela B.2 – Teste de raiz unitária de Phillips–Perron para as séries temporais do segundo ensaio (2004–2024).

Variável	Defasagens	Estatística PP	Valor-p
π_t	20	–8,3396	<0,0001
π_{t-1}	20	–8,3409	<0,0001
$E_t[\pi_{t+1}]$	20	–7,6420	<0,0001
x_{t-1}	20	–3,3517	0,0127

Fonte: Elaborado pelo autor, a partir de dados do Banco Central do Brasil (BCB).

Os resultados apresentados na Tabela B.2 indicam rejeição da hipótese nula de raiz unitária para todas as variáveis analisadas ao nível de 5% de significância. As séries de inflação corrente (π_t), inflação defasada (π_{t-1}) e expectativas de inflação ($E_t[\pi_{t+1}]$) apresentam valores-p substancialmente inferiores a 5%, evidenciando forte rejeição da hipótese de não estacionariedade. O hiato do produto defasado (x_{t-1}), por sua vez, também rejeita a hipótese nula ao nível de 5%, ainda que com menor margem relativa. Em conjunto, os resultados sugerem que, no período considerado, as séries analisadas exibem comportamento estacionário em torno de uma média constante.

Ressalta-se, contudo, que a realização desses testes possui caráter estritamente exploratório e documental, uma vez que o modelo *LightGBM* não impõe, como pressupostos formais, condições de estacionariedade das séries. Ainda assim, a evidência empírica apresentada contribui para a transparência analítica do estudo e para a compreensão das propriedades estatísticas básicas das variáveis utilizadas, sem implicar em restrições adicionais à estratégia de modelagem preditiva adotada.