

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA
DEPARTAMENTO DE CIÊNCIAS ECONÔMICAS
GRADUAÇÃO EM CIÊNCIAS ECONÔMICAS**

MARCELO AUGUSTO OLIVEIRA MARTINS

**Modelo de Previsão do IPCA para o ano de 2026 no Brasil: Uma Análise
Via Método de Regressão Dinâmica**

Juiz de Fora
2025

MARCELO AUGUSTO OLIVEIRA MARTINS

**Modelo de Previsão do IPCA para o ano de 2026 no Brasil: Uma Análise
Via Método de Regressão Dinâmica**

Monografia submetida ao Departamento de Ciências Econômicas da Universidade Federal de Juiz de Fora para inscrição do trabalho de monografia vinculado ao curso de Economia sob orientação do Prof. Dr. Alexandre Zanini.

Juiz de Fora

2025

Oliveira Martins, Marcelo Augusto.

Modelo de Previsão do IPCA para o ano de 2026 no Brasil : Uma Análise Via Método de Regressão Dinâmica / Marcelo Augusto Oliveira Martins. -- 2025.

40 p.

Orientador: Alexandre Zanini

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Juiz de Fora, Faculdade de Economia, 2025.

1. Previsão. 2. IPCA. 3. Inflação. 4. Regressão Dinâmica. I. Zanini, Alexandre, orient. II. Título.



UNIVERSIDADE FEDERAL DE JUIZ DE FORA
REITORIA - FACECON - Depto. de Economia

FACULDADE DE ECONOMIA / UFJF

ATA DE APROVAÇÃO DE MONOGRAFIA II (MONO B)

Na data de 02/12/2025, a Banca Examinadora, composta pelos professores

1 - Alexandre Zanini - orientador; e

2 - Cláudio Roberto Fóffano Vasconcelos,

reuniu-se para avaliar a monografia do acadêmico **MARCELO AUGUSTO OLIVEIRA MARTINS**, intitulada: **MODELO DE PREVISÃO DO IPCA PARA O ANO DE 2026 NO BRASIL: UMA ANÁLISE VIA MÉTODO DE REGRESSÃO DINÂMICA.**

Após primeira avaliação, resolveu a Banca sugerir alterações ao texto apresentado, conforme relatório sintetizado pelo orientador. A Banca, delegando ao orientador a observância das alterações propostas, resolveu **APROVAR** a referida monografia.

ASSINATURA ELETRÔNICA DOS PROFESSORES AVALIADORES



Documento assinado eletronicamente por **Alexandre Zanini, Professor(a)**, em 02/12/2025, às 17:43, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Claudio Roberto Fóffano Vasconcelos, Professor(a)**, em 02/12/2025, às 19:04, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **2776347** e o código CRC **817D1C24**.

Referência: Processo nº 23071.954532/2025-97

SEI nº 2776347

RESUMO

O presente trabalho tem como foco a análise da inflação brasileira, buscando compreender os principais fatores que influenciam seu comportamento e impacto na economia nacional. O objetivo central é prever a evolução do índice de inflação no Brasil até o ano de 2026. Para isso, foi realizado um levantamento da série histórica do índice de preços ao consumidor (IPCA) junto a variáveis macroeconômicas relevantes, como a taxa de câmbio, taxa Selic e preços de combustíveis, mais especificamente da gasolina e diesel. Foi aplicado o Método de Regressão Dinâmica (MRD), visando projetar cenários futuros através da equação de previsão gerada. Os resultados obtidos podem servir como base para decisões estratégicas em diversos setores da economia, tanto público quanto privado, além de fomentar estudos mais aprofundados sobre os mecanismos que afetam a inflação no país.

Palavras-chave: inflação; IPCA; previsão econométrica; séries temporais; Brasil.

ABSTRACT

This study focuses on analyzing Brazilian inflation, aiming to understand the key factors that influence its behavior and impact on the national economy. The primary objective is to forecast the evolution of Brazil's inflation index (IPCA) through 2026. To achieve this, historical data on the IPCA was compiled alongside relevant macroeconomic variables such as the exchange rate, Selic interest rate, and international commodity prices—particularly oil. The Dynamic Regression Method (DRM) was applied to generate predictive equations and simulate future scenarios. The results are intended to support strategic decision-making across public and private sectors and to encourage further research into the mechanisms driving inflation in Brazil.

Keywords: inflation; IPCA; econometric forecasting; time series; Brazil

LISTA DE ILUSTRAÇÕES

Figura 1: Construção de um modelo de regressão dinâmica	20
Figura 2: Autocorrelação dos erros	29
Figura 3: Previsão para os próximos 16 meses do IPCA	32

LISTA DE TABELAS

Tabela 1: Variáveis utilizadas no modelo	26
Tabela 2: Poder de Explicação e testes do modelo realizado	28

LISTA DE ABREVIATURAS E SIGLAS

IPCA	Índice Nacional de Preços ao Consumidor Amplo
BCB	Banco Central do Brasil
IBGE	Instituto Brasileiro de Geografia e Estatística
MRD	Método de Regressão Dinâmica
POF	Pesquisa de Orçamentos Familiares
RMI	Regime de Metas para Inflação
SNIPC	Sistema Nacional de Índices de Preços ao Consumidor

SUMÁRIO

1 INTRODUÇÃO	7
2 A HIPERINFLAÇÃO E A CRISE DA "DÉCADA PERDIDA" (1980-1994)	9
2.1 VARIÁVEIS INFLACIONÁRIAS.....	12
3 MÉTODO DE REGRESSÃO DINÂMICA.....	14
3.1 CONSIDERAÇÕES INICIAIS	14
3.2 ESTRUTURA DOS MODELOS DE REGRESSÃO DINÂMICA.....	16
3.2.1 MODELOS DE REGRESSÃO COCHRANE-ORCUTT GENERALIZADOS	17
3.3 CONSTRUÇÃO DE MODELOS DE REGRESSÃO DINÂMICA	18
3.4 TESTES USADOS NOS MODELOS DE REGRESSÃO DINÂMICA.....	21
3.4.1 TESTES DE VERIFICAÇÃO DA “DINÂMICA” DO MODELO.....	21
3.4.2 TESTES PARA A ESPECIFICAÇÃO DAS VARIÁVEIS CAUSAIS	22
3.4.3 TESTES BASEADOS NA AUTOCORRELAÇÃO DOS RESÍDUOS	23
4 ANÁLISE DE DADOS E RESULTADOS	25
4.1 BASE DE DADOS	25
4.2 A EQUAÇÃO DE PREVISÃO	27
4.3 RESULTADOS DA PREVISÃO	29
5 CONCLUSÃO.....	33
6 REFERÊNCIAS BIBLIOGRÁFICAS	35

1 INTRODUÇÃO

O Índice Nacional de Preços ao Consumidor Amplo (IPCA) é o indicador oficial utilizado pelo Banco Central do Brasil para acompanhar o cumprimento do sistema de metas de inflação. É produzido pelo Instituto Brasileiro de Geografia e Estatística (IBGE), por meio do Sistema Nacional de Índices de Preços ao Consumidor (SNIPC), e tem como objetivo medir a variação de preços de um conjunto de bens e serviços que compõem o consumo das famílias brasileiras (IBGE, [s.d]).

O IPCA também é utilizado como indexador de contratos, investimentos e como ferramenta para auxiliar no planejamento do orçamento público e privado. Nesse sentido, é bastante comum no início de cada ano que a imprensa e as grandes consultorias façam especulações sobre as tendências econômicas.

As projeções sobre o comportamento das principais variáveis econômicas influenciam diretamente as decisões de investidores e analistas do mercado financeiro. No entanto, não é apenas esse setor que se interessa por essas variáveis. O próprio Banco Central do Brasil monitora e divulga as expectativas do mercado por meio do Boletim Focus, um relatório semanal que consolida as projeções de diversas instituições (BCB, [s.d]).

Conforme apontado em Bresser-Pereira (2003), o descontrole da inflação, isto é, a perda de estabilidade do índice, pode causar sérios desequilíbrios econômicos, como aumento da dívida externa e redução nos níveis de poupança e investimento. Por isso, prever cenários futuros de forma precisa é essencial para decisões econômicas mais ágeis e eficazes, a fim de mitigar impactos no desenvolvimento do país.

A metodologia do IPCA, desenvolvida pelo Instituto Brasileiro de Geografia e Estatística (IBGE), baseia-se em uma cesta de consumo que reflete os hábitos da população. A definição dos produtos e serviços que compõem essa cesta, bem como o peso de cada um, é estabelecida pela Pesquisa de Orçamentos Familiares (POF). Essa pesquisa garante que o índice represente o custo de vida real das famílias e a coleta dos dados dela é realizada pelo SNIPC mensalmente, do dia 01º ao dia 30, nos estabelecimentos comerciais e de prestação de serviços, concessionárias de serviços públicos e de internet e nos domicílios para avaliação de preços de aluguel e condomínio. (IBGE, [s.d])

Segundo o Instituto Brasileiro de Geografia e Estatística (IBGE, 2025), atualmente, o alvo da análise do IPCA abrange famílias com rendimentos de 1 a 40 salários mínimos, independente da fonte, residente nas áreas de abrangência do SNIPC, sendo elas: regiões metropolitanas de Belém, Fortaleza, Recife, Salvador, Belo Horizonte, Vitória, Rio de Janeiro, São Paulo, Curitiba, Porto Alegre, além do Distrito Federal e dos municípios de Goiânia, Campo Grande, Rio Branco, São Luís e Aracaju.

O objetivo deste trabalho é realizar uma previsão para o IPCA até o ano de 2026, utilizando o Método de Regressão Dinâmica (MRD). Conforme Zanini (2000), “nos modelos de regressão dinâmica são combinadas as dinâmicas de séries temporais com suas variáveis explicativas, devendo ser utilizada quando existe uma estrutura de dependência entre a variável de interesse e variáveis causais e, ao mesmo tempo, quando a estrutura de correlação da série dependente indicar que não será possível supor a independência dos erros”.

Apesar de existirem trabalhos que buscam prever o IPCA, muitos deles utilizam outros métodos de previsão. Coelho Jr. (2004) utilizou a metodologia Box e Jenkins para prever os indicadores econômicos de inflação, taxa de juros, taxa de câmbio e Ibovespa. Santos, Ferreira e Castelar (2016) utilizaram os modelos Autorregressivo Integrado de Média Móvel (ARIMA) e Vetor Autorregressivo (VAR) para comparar previsões da inflação acumulada em 12 meses com os resultados divulgados pela pesquisa Focus do Banco Central do Brasil. Barbosa (2019) também utilizou a metodologia Box e Jenkins para prever a inflação no Brasil, combinando-a com um modelo baseado na Teoria Econômica.

Com isso, utilizando o Método de Regressão Dinâmica, busca-se oferecer uma visão diferenciada para prever o IPCA no Brasil, possibilitando uma análise mais aprofundada da trajetória futura do índice.

Este trabalho está estruturado em cinco seções. Além desta introdução, o capítulo 2 apresenta o contexto histórico da inflação no Brasil e as variáveis usadas no modelo. O capítulo 3 descreve a metodologia da Regressão Dinâmica; o capítulo 4 analisa os dados e resultados; e o capítulo 5 apresenta as conclusões.

2 A HIPERINFLAÇÃO E A CRISE DA "DÉCADA PERDIDA" (1980-1994)

Historicamente a inflação vem sendo um dos principais desafios econômicos do Brasil. A década de 1980 foi um dos períodos mais críticos, marcado por forte instabilidade e a principal causa do descontrole inflacionário dessa década foi o desequilíbrio financeiro e estrutural do setor público, somado à dificuldade de financiamento do déficit público que gerou grandes tensões inflacionárias (CONTADOR, 1985).

A crise econômica que se instaurou no Brasil durante a década de 1980 não pode ser compreendida de forma isolada, pois estava fortemente associada ao contexto internacional. Segundo Bresser-Pereira (2003, p. 72), “a elevação das taxas de juros internacionais e o segundo choque do petróleo agravaram o endividamento externo e comprometeram a estabilidade macroeconômica dos países latino-americanos”. Os fatores externos desempenharam papel decisivo na intensificação da crise interna brasileira, especialmente pelo aumento do custo de financiamento e pela deterioração das contas externas.

Esse quadro, aliado à elevada dívida externa acumulada durante o período do chamado milagre econômico, impôs ao Brasil severas restrições de financiamento, resultando na denominada “década perdida” (GONÇALVES, 1991). A inflação, que já apresentava uma tendência de crescimento, acelerou-se drasticamente, atingindo patamares anuais de três e até quatro dígitos. Por exemplo, o Índice Nacional de Preços ao Consumidor Amplo (IPCA) acumulou uma variação de 1.972,91% em 1989 (IPEADATA, [s.d.]).

Além da falta de estruturação do setor público e desequilíbrio financeiro, de acordo com Rotta et al. (2018), o processo de redemocratização do país foi acompanhado por sucessivas e frustradas tentativas de estabilização econômica como os Planos Cruzado (1986), Bresser (1987) e Verão (1989), todos baseados no congelamento de preços e salários, e incapazes de conter o avanço inflacionário.

No entanto, a falta de um ajuste fiscal consistente e a ineficácia em quebrar a inércia inflacionária, enraizada na indexação da economia, levaram ao fracasso dessas iniciativas (FRANCO, 1995). O ápice da crise inflacionária chegou no início da década de 1990, quando o Brasil mergulhou em um quadro de hiperinflação. Em

março de 1990, o IPCA registrou sua maior variação mensal histórica, atingindo 82,39% (IBGE, [s.d.]). Esse período de descontrole monetário exigiu medidas drásticas por parte do governo recém-empossado de Fernando Collor de Mello.

O Plano Collor, implementado em março de 1990, incluiu medidas que resultaram no bloqueio da liquidez de parte considerável dos haveres financeiros (BRASIL, Medida Provisória n. 168, de 15 mar. 1990). Embora tenha provocado uma queda da inflação nos meses seguintes (15,52% em abril e 7,59% em maio de 1990), o plano mostrou-se insustentável, e a inflação voltou a acelerar, mantendo-se em patamares elevados até meados de 1994 (IBGE, [s.d.]). O contexto político de impeachment do presidente Collor, em 1992, adicionou mais um elemento de instabilidade institucional ao cenário econômico. Segundo Maria Clara Prado (2005), esse período representou um ponto-chave para o controle da inflação, pois “[...] o mandato de Itamar Franco constituiu o cenário em que o Plano Real foi preparado e lançado, após extensa fragilidade econômica e política” (PRADO, 2005, p. 145).

O lançamento do Plano Real, em 1994, marcou um ponto de inflexão na história do Brasil. Idealizado por uma equipe econômica liderada por Fernando Henrique Cardoso, foi um processo gradual de estabilização que resultou na criação de uma nova moeda, o Real (GIAMBIAGI, 2004). Como destaca Franco (1995, p. 52), “o sucesso do Plano Real deveu-se, sobretudo, à quebra da inércia inflacionária e à imposição de uma disciplina fiscal e monetária que sustentou a credibilidade da nova moeda”. Em julho de 1994, o IPCA caiu para 6,84% e, em agosto, para 1,86%, sinalizando o fim da hiperinflação no país (IBGE, [s.d.]).

O período imediatamente posterior ao lançamento do Plano Real (1994) e anterior à adoção do Regime de Metas de Inflação (1999) foi crucial para a consolidação da estabilidade de preços. Nessa fase, a política econômica concentrou-se em manter a nova moeda ancorada e, como observa Silva (2002), foi conduzida à implementação de programas de estabilização que têm aspectos em comum, dentre eles o fato de utilizarem a taxa de câmbio como âncora nominal.

Embora o Plano Real tenha sido inicialmente bem-sucedido, o modelo adotado gerou um novo problema macroeconômico. Conforme Giambiagi e Além (2011), embora a valorização cambial tenha sido fundamental para conter a inflação no início do programa de estabilização, ela resultou em um aumento progressivo dos déficits em conta corrente e, consequentemente, na elevação da vulnerabilidade externa do país. A política monetária adotada buscava sustentar a âncora cambial por meio da

elevação das taxas de juros, visando atrair capital estrangeiro e financiar o déficit externo (CARVALHO, 2006). Segundo Carvalho (2006), para compensar o risco cambial e estimular o ingresso de capitais de curto prazo as taxas de juros internas eram mantidas em níveis elevados. Esse modelo, denominado tripé macroeconômico, revelou sua fragilidade diante das crises financeiras internacionais (México em 1994, Ásia em 1997 e Rússia em 1998), culminando na crise cambial brasileira de janeiro de 1999. O abandono do câmbio fixo e a adoção do Regime de Metas de Inflação (RMI) representaram, segundo Giambiagi (2004), o início de um novo arcabouço de política monetária no Brasil.

O Regime de Metas de Inflação (RMI), instituído formalmente pelo Decreto nº 3.088/1999, consolidou-se como o principal instrumento de política monetária para garantir a estabilidade de preços (CARVALHO, 2006). Como mostra Weppo (2021), o RMI se fundamenta em três pilares: o estabelecimento de uma meta central para o IPCA, o regime de câmbio flutuante e a utilização da Taxa Selic como principal instrumento de política monetária.

A adoção do RMI demonstrou eficácia em ancorar as expectativas inflacionárias. Contudo, o regime foi testado por pressões externas e internas, e a inflação anual, medida pelo IPCA, registrou picos notáveis, como em 2002, quando a crise de confiança e a desvalorização cambial levaram o índice a 12,53%. Conforme Weppo (2021), durante o primeiro mandato do governo Lula, o regime de metas enfrentou um período de forte desvalorização cambial e aumento das expectativas de inflação. Já o contexto internacional da primeira década do século XXI foi relativamente favorável, com a valorização das commodities impulsionando a economia brasileira (BRAGA, 2011).

Um novo teste para a eficácia do RMI foi a Crise Financeira Global de 2008. O Brasil, diferentemente das economias desenvolvidas, não sofreu impacto imediato, mas enfrentou aversão ao risco e redução nas exportações. A resposta do governo, por meio de estímulos monetários e fiscais, evitou uma recessão profunda. Contudo, como afirma Freitas (2009), a inflação manteve-se controlada, embora acima do centro da meta, encerrando 2008 em 5,9%.

Seguindo adiante, a década de 2010 pode ser dividida em dois momentos. A primeira metade foi marcada por um crescimento pouco significativo e com sinais de esgotamento. A inflação, nesse período, mostrou-se mais persistente, pressionando frequentemente o teto da meta estabelecida pelo Banco Central (Oreiro, 2017). Já a

segunda metade da década foi considerada uma das mais severas da história recente do país. Como afirma Oreiro (2017), a economia brasileira viveu, entre 2014 e 2016, a mais profunda e prolongada recessão desde a década de 1980. O ano de 2015 foi particularmente crítico, com o IPCA atingindo 10,67%, o maior índice desde 2002, o que levou o Banco Central a elevar a taxa Selic para tentar ancorar novamente as expectativas.

O desafio mais recente veio com a pandemia de COVID-19 em 2020, que gerou um novo choque inflacionário, mas com características distintas. A oferta global, a interrupção das cadeias produtivas e a forte desvalorização cambial pressionaram os preços, especialmente de alimentos e combustíveis. A inflação, que havia fechado 2019 em 4,31%, disparou, atingindo 10,06% em 2021 (IBGE, [s.d.]). Segundo Feijó, Araújo e Bresser-Pereira (2022), o aumento de preços observado a partir de 2020 foi amplamente influenciado por fatores de oferta, associados à pandemia e ao comportamento dos preços internacionais de commodities. A resposta do Banco Central foi a elevação agressiva da taxa de juros, buscando conter a inflação e evitar a desancoragem das expectativas, em um contexto de alta incerteza política e fiscal.

Em síntese, a análise histórica da inflação brasileira evidência que o controle inflacionário no Brasil foi alcançado por meio de uma combinação de políticas econômicas, consolidação estrutural e aprendizado diante de crises passadas e políticas mal sucedidas. O país conseguiu se recuperar, ainda que gradualmente, dos cenários de hiperinflação, consolidando um regime de estabilidade relativa. Como observa Giambiagi (2011), a experiência brasileira mostra que a estabilidade de preços depende não apenas de medidas monetárias, mas de um conjunto de instituições que sustentem a credibilidade da política econômica.

2.1 VARIÁVEIS INFLACIONÁRIAS

A inflação no Brasil possui vários fatores de influência, por isso, precisa ser analisada de uma forma que leve em consideração esses efeitos ao longo do tempo. O Método de Regressão Dinâmica (MRD) pode ser uma ferramenta importante nesse processo de análise, pois considera as defasagens, ou seja, o impacto que um choque pode ter nos períodos seguintes. Esse método também permite desagregar o Índice Nacional de Preços ao Consumidor Amplo (IPCA) e cruzar os dados com variáveis

macroeconômicas importantes. Como destacam Martinez e Cerqueira (2013), esse tipo de modelo ajuda a entender melhor o papel das expectativas, dos preços administrados e dos choques de oferta no comportamento da inflação.

A escolha das variáveis explicativas busca representar os principais canais que pressionam a inflação: a demanda, os custos e os choques externos. A Taxa Selic e a Taxa de Câmbio têm papel central nesse processo. A Selic é o principal instrumento da política monetária e seus efeitos aparecem com atraso, influenciando o custo do crédito e, por consequência, a demanda agregada (FREITAS JUNIOR, 2023). Já a Taxa de Câmbio funciona como o principal canal de transmissão dos choques externos, afetando os preços de produtos importados por meio do repasse cambial (ARAÚJO, 2023). Por isso, o modelo considera defasagens nessas variáveis, permitindo capturar como esses impactos se espalham ao longo do tempo na economia.

Observando por outro ângulo, a inflação brasileira costuma ser fortemente influenciada por choques de custo o que justifica a inclusão de variáveis que capturam pressões de oferta e de insumos como o IGP-M e o salário mínimo. O IGP-M, por exemplo, atua como um indicador antecipado de custos no atacado, servindo como sinal de futuras pressões sobre o IPCA (BRAGA, 2016; MARTINEZ, 2011).

Além disso, variáveis como o preço do petróleo e o custo da energia elétrica ajudam a representar choques de grande impacto. O petróleo reflete choques globais de custo que se espalham pelos preços domésticos (FREITAS, 2025). Já a energia elétrica representa um choque interno, sensível a fatores climáticos e regulatórios, que afeta diretamente o custo de produção em diversos setores, uma vez que os choques de oferta, como os relacionados à energia elétrica e combustíveis, possuem efeito disseminado sobre os custos de produção e sobre o nível geral de preços. (MODENESI; FERRARI FILHO, 2011).

Assim, ao incorporar essas variáveis macroeconômicas, o Método de Regressão Dinâmica (MRD) pode constituir uma ferramenta para analisar e prever a dinâmica da inflação brasileira, oferecendo resultados consistentes com as melhores práticas de análise macroeconômica aplicada no país.

É importante salientar que o objetivo do trabalho não é avaliar a causalidade entre as variáveis e sim quantificar o impacto marginal de cada variável explicativa sobre a dinâmica do IPCA.

3 MÉTODO DE REGRESSÃO DINÂMICA

Neste capítulo será descrita a metodologia utilizada neste trabalho e que foi integralmente tirada do trabalho de Zanini (2000).

3.1 CONSIDERAÇÕES INICIAIS

Nos modelos de regressão linear estudados comumente na literatura¹, supõe-se que os erros “gerados” pelo modelo possuem algumas características como: média zero, variância constante, distribuição Normal e independência (o que implica na inexistência de correlação serial).

Entretanto, na prática, ao modelar séries econômicas, os resíduos tendem a apresentar correlações positivas, e erros positivos tendem a ser seguidos por outros também positivos (o mesmo comportamento é observado para resíduos negativos). O gráfico dos resíduos *versus* o índice dos tempos revela, nesta situação, que os resíduos tendem a se agrupar em “blocos” de resíduos com o mesmo sinal.

Ao tentar modelar uma série temporal através de um modelo de regressão, a hipótese de independência dos ruídos pode não ser realista, e os resultados e testes usados nos modelos de regressão não são válidos. Por exemplo, algumas das consequências da autocorrelação dos resíduos são:

- 1) Os estimadores usuais por mínimos quadrados são ainda não tendenciosos, mas não têm variância mínima.
- 2) Os estimadores da variância e dos erros padrões dos coeficientes da regressão são subestimados, o que levaria à conclusão de que os estimadores são mais precisos do que na realidade.
- 3) Os intervalos de confiança para os parâmetros da regressão e os testes de hipóteses relacionados a estes intervalos perdem a validade, como uma consequência direta de 2).

Desta forma, estes três motivos implicam na necessidade de procurar procedimentos para tratar o problema de autocorrelação dos erros, pois ignorá-los leva, em geral, a inúmeras conclusões errôneas.

¹ Gujarati, D.N (1995).

Em particular, dado que a hipótese de independência dos erros não é realista no contexto de séries temporais, os modelos de regressão dinâmica estendem os modelos usuais de regressão ao levantarem esta restrição.

Os modelos de regressão dinâmica combinam a dinâmica de séries temporais e o efeito de variáveis explicativas. Atenta-se que o termo “regressão dinâmica” não indica que os parâmetros do modelo evoluem no tempo². Ao contrário, a palavra “dinâmica” significa aqui um modelo de regressão no qual incluímos a estrutura de dependência de uma série temporal.

Modelos de regressão dinâmica devem ser usados quando existe uma estrutura de dependência entre a variável de interesse e variáveis causais e, ao mesmo tempo, quando a estrutura de correlação da série dependente (série a ser explicada) indicar que não podemos supor a independência dos erros.

Salienta-se que a estimação de parâmetros num modelo de regressão dinâmica é feita através de mínimos quadrados ordinários (MQO)³, a exemplo dos modelos de regressão usuais. Entretanto, a estimação em modelos de regressão dinâmica é mais complicada, e envolve um procedimento iterativo com vários estágios.

Nos modelos de regressão dinâmica, a variável dependente é explicada por seus valores defasados e pelos valores atuais e passados de variáveis causais ou exógenas. Atenta-se, neste momento, para outra distinção entre os modelos de regressão dinâmica e modelos de espaço de estados. Nos modelos de regressão dinâmica, as variáveis exógenas são tratadas como “números fixos” e não como variáveis aleatórias. Já nos modelos de espaço de estados, as variáveis exógenas são tratadas como séries temporais, ou seja, realizações de processos estocásticos. Logo, no contexto da modelagem em espaço de estados, a estrutura de autocovariâncias e autocorrelações das séries de variáveis exógenas é uma informação de interesse, enquanto este aspecto é ignorado nos modelos de regressão dinâmica.

² Caso dos modelos de espaço de estados que usam o Filtro de Kalman (Hamilton, 1994).

³ Dudewicz & Mishra (1998). Na verdade, aplica-se MQO em dois estágios.

3.2 ESTRUTURA DOS MODELOS DE REGRESSÃO DINÂMICA

Os modelos de regressão dinâmica podem ser descritos pela equação:

$$\phi(B)Y_t = \beta x_t + \varepsilon_t \quad (3.1)$$

onde:

Y_t = variável dependente (endógena) no instante t

β = vetor de coeficientes das variáveis causais, que será estimado por mínimos quadrados

x_t = vetor de variáveis causais (exógenas)⁴ no instante t

ε_t = ruído aleatório associado ao modelo, onde supomos que os ε_t são independentes e identicamente distribuídos com densidade $N(0, \sigma^2)$

$\phi(B)$ = polinômio autoregressivo de ordem p , isto é:

$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ sendo B o operador de atraso

A estrutura do modelo de regressão dinâmica permite considerar como elementos x_t variáveis causais e também suas defasagens.

A presença do polinômio $\phi(B)$ no modelo traz uma grande flexibilidade desta classe de modelos mas, ao mesmo tempo, dificulta a procura por um modelo adequado. Observa-se que, se $\phi(B) = 1$, não existem defasagens da variável dependente, e a interpretação do modelo é muito simples, pois as variáveis causais influenciam diretamente a variável endógena. Ao contrário, quando $\phi(B) \neq 1$, o modelo pode ser usado para representar relações bastante complicadas.

Por fim, salienta-se que uma grande diferença entre os modelos de Regressão Dinâmica e os modelos ARIMA consiste no fato dos modelos de regressão dinâmica incluírem efeitos de variáveis causais através do termo βx_t . Os modelos ARIMA univariados de Box e Jenkins, por sua vez, não incluem tais efeitos, e apenas o passado da série Y_t e os valores defasados da série de erros são usados na modelagem e previsão da série Y_t .⁵

⁴ As variáveis exógenas representadas por x_t têm seus valores determinados “fora” do modelo de regressão, enquanto a variável endógena Y_t é determinada a partir das variáveis exógenas e do ruído ε_t .

⁵ A metodologia Box & Jenkins também possui um modelo causal, o chamado modelo de Função de Transferência. O software Autobox ajusta este tipo de modelo.

O modelo de regressão dinâmica que pode ser considerado como um caso particular do que é conhecido na literatura como modelos de Cochrane e Orcutt generalizados que será descrito brevemente a seguir.

3.2.1 MODELOS DE REGRESSÃO COCHRANE-ORCUTT GENERALIZADOS

O modelo de regressão generalizado de Cochrane e Orcutt (1949) é dado por:

$$\phi(B)Y_t = \beta x_t + w_t \quad (3.2)$$

$$R(B)w_t = \varepsilon_t \quad (3.3)$$

Onde $R(B)$ = polinômio autoregressivo

Pode-se notar que a equação (3.2) tem a mesma forma da equação (3.1) da regressão dinâmica, entretanto os erros w_t apresentam uma estrutura AR dada pela equação 3.3⁶.

Este modelo dado pelas equações (3.2) e (3.3) ainda pode ser descrito em termos de uma única equação como a seguir. Note que da equação (3.2):

$$w_t = \phi(B)Y_t - \beta x_t$$

Substituindo esta última expressão na equação (3.3) tem-se que:

$$R(B)[\phi(B)Y_t - \beta x_t] = \varepsilon_t \quad (3.4)$$

Desta última expressão nota-se que o modelo de regressão generalizado de Cochrane e Orcutt introduz defasagens tanto na variável dependente (Y_t) quanto nas causais. A expressão (3.4) indica também que a relação de causalidade entre Y_t e x_t não é afetada pela introdução do polinômio autoregressivo $R(B)$.

Esta última equação pode ainda ser escrita em termos de novas variáveis Y^*_t e x^*_t dadas por:

$$Y^*_t = R(B)Y_t \text{ e}$$

$$x^*_t = R(B)x_t$$

⁶ A formulação original de Cochrane e Orcutt supõe que os ruídos w_t apresentam apenas uma estrutura AR(1), ou seja, a equação (4.3) é dada por: $w_t = \alpha w_{t-1} + \varepsilon_t$ onde os ε_t são i.i.d e apresentam distribuição $N(0, \sigma^2)$.

onde $R(B)$ é chamado de “fator comum” e representa a estrutura de correlação presente no erro w_t .

A equação obtida então usando-se estas novas variáveis é:

$$\phi(B)Y^*_t = \beta x^*_t + \varepsilon_t \quad (3.5)$$

Logo, o modelo de regressão generalizado de Cochrane e Orcutt reduz-se ao modelo de regressão dinâmica usual ao se considerar as novas variáveis Y^*_t e x^*_t . O modelo original de Cochrane e Orcutt tem como fator comum $R(B) = 1 - \alpha B$ e então a equação (3.5) reduz-se a:

$$\phi(B).[Y_t - \alpha Y_{t-1}] = \beta[x_t - \alpha x_{t-1}] + \varepsilon_t \quad (3.6)$$

Salienta-se que, neste modelo, o procedimento de estimação é seqüencial. A estimativa inicial de α é 0, e a partir dela estimamos β e $\phi(B)$ por mínimos quadrados ordinários. A partir destas estimativas encontra-se um estimador de $R(B)$ através da equação $R(B)w_t = \varepsilon_t$. O polinômio estimado $R(B)$ é então usado para transformar Y_t e x_t e reestimar β e $\phi(B)$. O processo é repetido até que se alcance a convergência dos parâmetros.

3.3 CONSTRUÇÃO DE MODELOS DE REGRESSÃO DINÂMICA

Geralmente os modelos econométricos têm uma estrutura conhecida, baseada em considerações teóricas e o problema reduz-se ao problema de estimação dos parâmetros do modelo já conhecido. Entretanto, este é raramente o caso no contexto de séries temporais, onde a estratégia é construir modelos a partir dos dados.

A estratégia usualmente empregada para construir um modelo de regressão dinâmica é uma estratégia *bottom-up*, isto é, partimos de um modelo simples e o refinamos e incluímos novas variáveis até encontrar um modelo apropriado. A elaboração de um modelo de regressão dinâmica é muitas vezes um procedimento difícil, pois é preciso não apenas escolher as variáveis a serem incluídas no modelo, mas também os *lags* (defasagens) destas variáveis.

Na definição do modelo adequado, é necessário levar em conta não só a significância dos parâmetros, mas também uma certa estrutura “lógica” do modelo. Por exemplo, vendas (ou demanda) de um produto são geralmente afetadas por seu preço. O aumento do preço, por sua vez, tende a diminuir as vendas (ou demanda), e

vice-versa. Logo, se o modelo de regressão encontrado para explicar venda pelo preço apresenta um coeficiente positivo para a variável preço, é bom desconfiar por mais bem ajustado que esteja o modelo, pois a relação apontada pelo modelo não é, em geral, verdadeira⁷. Em síntese, na escolha de um modelo de regressão, não é necessário apenas encontrar um ajuste de parâmetros adequado, mas fundamentalmente faz-se mister verificar se os coeficientes estimados são coerentes.

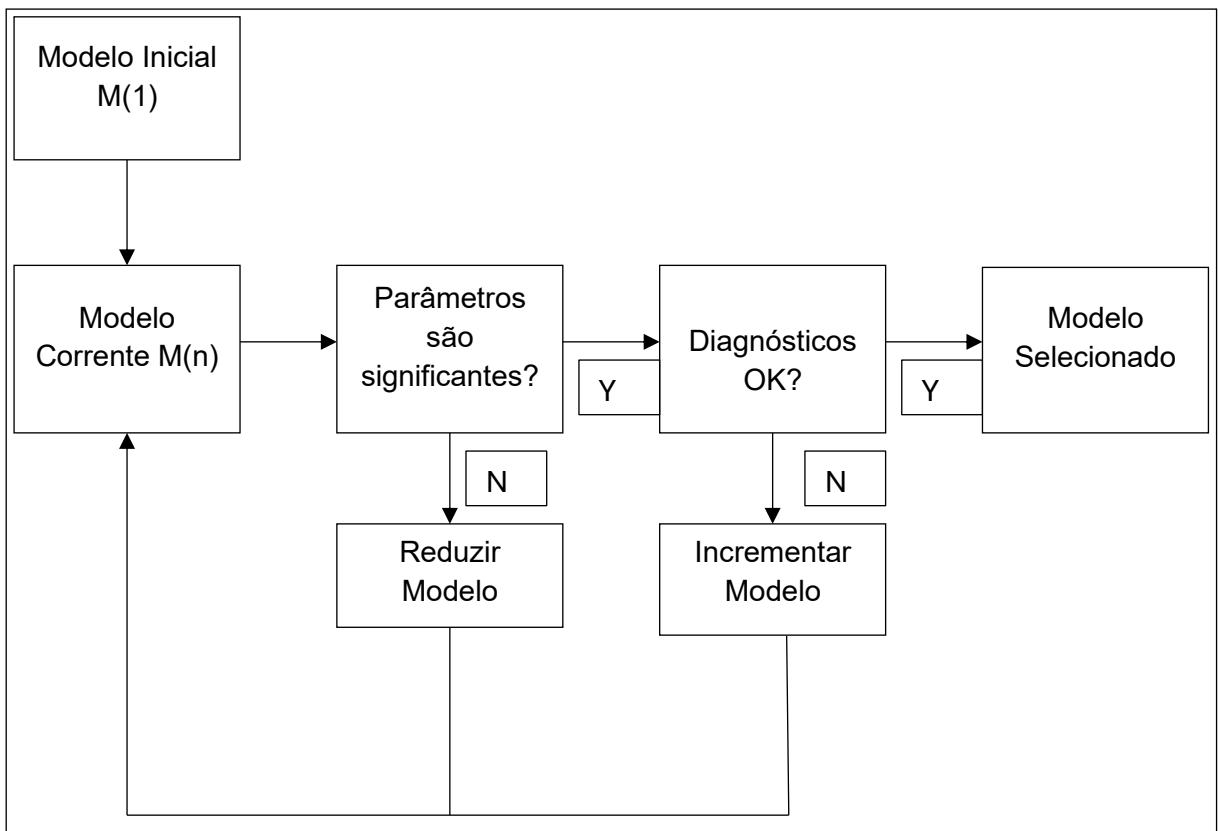
As previsões geradas por um modelo de regressão dinâmica dependem não só de valores passados da série, mas também dos valores previstos para as variáveis causais. Logo, para obtermos as previsões da série Y_t para $T+1$, $T+2$, $T+3$, etc, é necessário fornecer ao modelo os valores futuros do vetor de variáveis causais x_t . Se as previsões destas variáveis exógenas não forem apropriadas, o modelo de regressão dinâmica irá também gerar previsões inadequadas.

Isto caracteriza um aspecto importante dos modelos de regressão dinâmica que consiste na possibilidade de consecução de cenários ao se chegar a um modelo relacional de variáveis dependentes em relação a variáveis explicativas. Isto é, surge a possibilidade de montagem de vários cenários para as variáveis causais o que enriquece, por exemplo, qualquer trabalho de planejamento de vendas de um determinado produto.

Feitas estas considerações, o fluxograma a seguir indica, de maneira genérica, os passos usados na construção de um modelo de regressão dinâmica.

⁷ Na verdade, “casos estranhos” como este ocorrem na prática com certa frequência e uma possível saída é olhar para o coeficiente da variável preço com alguma defasagem, e verificar se é possível encontrar algum resultado coerente.

Figura 1: Construção de um modelo de regressão dinâmica



Fonte: Zanini, A. (2000).

Como dito anteriormente, a especificação correta de um modelo de regressão dinâmica envolve a precisa especificação da relação causal entre as variáveis e da estrutura dinâmica do modelo.

Nos modelos de regressão dinâmica podem ser usadas também variáveis de intervenção (ou variáveis *dummy*). O objetivo deste tipo de procedimento é considerar situações atípicas como, por exemplo, aumento das vendas de brinquedo no Natal e no Dia da Criança (neste caso é razoável incluir *dummies* para os meses de dezembro e outubro no modelo). O mesmo procedimento pode ser usado para levar em conta os efeitos de situações incomuns como greves e planos econômicos⁸.

Os modelos de regressão dinâmica incorporam ainda diretamente a sazonalidade da série ao modelo, ao invés de supor que a série será previamente dessazonalizada. Atenta-se que existem duas maneiras de tratar a sazonalidade: via dummies sazonais ou diretamente, através de defasagens na variável dependente ou nos erros estruturados.

⁸ Variáveis *dummies* são geralmente definidas como 1 (no período de ocorrência do fato relevante) e 0 (fora deste período).

3.4 TESTES USADOS NOS MODELOS DE REGRESSÃO DINÂMICA

Como dito anteriormente, em regressão dinâmica a construção do modelo envolve vários passos até se chegar a um modelo “final”. Diversos testes da adequação de um modelo de regressão podem ser mencionados. Estes testes⁹ são aplicados em diversos estágios da modelagem da série. Temos, por exemplo:

- i) testes como o objetivo de definir a especificação do modelo explicativo;
- ii) testes visando encontrar a dinâmica do modelo, isto é, a inclusão ou não de variáveis defasadas,
- iii) testes para verificar o ajuste do modelo.

3.4.1 TESTES DE VERIFICAÇÃO DA “DINÂMICA” DO MODELO

Como dito anteriormente, a dinâmica de um modelo acontece através dos *lags* da variável dependente e/ou através da presença de erros estruturados num modelo de Cochrane-Orcutt. A cada momento da elaboração do modelo, são realizados testes de hipóteses sobre a “dinâmica” do modelo.

Em todos os casos a seguir, a hipótese nula afirma que a dinâmica do modelo está corretamente especificada, ou seja, a inclusão de outros *lags* da variável dependente ou outros erros estruturados não é necessária. A hipótese alternativa, em cada caso, representa a necessidade de inclusão de novos termos. Sendo assim tem-se:

1) Teste de defasagem da variável endógena

Suponha que a variável dependente Y_t e seus *lags* $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p-1}$ estão presentes no modelo atual. A hipótese alternativa consiste em adicionar a variável defasada Y_{t-p} ao modelo, isto é, adiciona-se o primeiro lag ainda não presente no modelo atual. Se esta variável for considerada significante, a hipótese nula é rejeitada e deve-se adicionar a variável Y_{t-p} ao modelo.

2) Teste da defasagem sazonal da variável endógena

Este teste é semelhante ao anterior. A hipótese alternativa consiste em adicionar ao modelo atual a variável defasada até o primeiro *lag* sazonal Y_{t-ps} ainda

⁹ A maioria dos testes empregados em regressão dinâmica é uma variante dos testes de Multiplicadores de Lagrange (testes LM) e são baseados na distribuição Qui-Quadrado.

não presente ao modelo. Se o coeficiente de Y_{t-pS} for significante, esta variável deve ser incluída no modelo, e a hipótese nula deve ser rejeitada.

3) Teste da seqüência de defasagens da variável endógena

A hipótese alternativa consiste em adicionar todos os lags da variável dependente que ainda não estão presentes no modelo.

4) Teste da defasagem dos resíduos

A hipótese alternativa consiste em adicionar ao modelo o primeiro termos defasado ε_{t-p} ainda não incluído no modelo atual.

5) Teste da defasagem sazonal dos resíduos

Na hipótese alternativa adiciona-se ao modelo atual o primeiro lag sazonal ε_{t-pS} ainda não presente no modelo.

6) Teste da seqüência de defasagens dos resíduos

Na hipótese alternativa adiciona-se às variáveis do modelo atual uma seqüência de resíduos defasados ε_{t-1} , ε_{t-2} , ε_{t-S} onde S é o período sazonal. É importante ressaltar que, na hipótese alternativa, inclui-se apenas os resíduos ainda ausentes no modelo atual.

3.4.2 TESTES PARA A ESPECIFICAÇÃO DAS VARIÁVEIS CAUSAIS

O objetivo de todos estes testes é verificar se a inclusão de uma ou mais variáveis ainda não contempladas no modelo resulta numa melhora do ajuste. Atentase para o fato de que os testes para a especificação de variáveis causais não se referem à parte dinâmica do modelo, e não tratam da inclusão de *lags* da variável dependente e de erros estruturados¹⁰.

1) Teste das variáveis causais excluídas

Neste teste verifica-se a necessidade de inclusão de cada uma das variáveis (escolhidas previamente para análise) mas que ainda não estão presentes no modelo.

¹⁰ Estes são realizados nos testes para a “dinâmica”.

Se quaisquer destas variáveis são consideradas significantes, deve-se incluí-las no modelo (talvez seqüencialmente) e “rodar” a mesma bateria de testes para verificar se a inclusão foi vantajosa.

2) Teste de tendência temporal

Este teste corresponde à inclusão de uma variável do tipo $X_t=t$ no modelo. Esta variável é útil em casos onde a série dependente não é estacionária.

3) Teste da defasagem das variáveis exógenas (causais)

Na hipótese alternativa inclui-se um *lag* adicional das variáveis causais já presentes no modelo atual.

4) Teste para a presença de funções não lineares das variáveis exógenas

Neste teste inclui-se o quadrado de cada variável exógena já presente no modelo. Todos os quadrados das variáveis exógenas são incluídos de uma só vez e, portanto, é necessário buscar quais (ou qual) quadrados são realmente significantes.

5) Teste do fator comum

Este teste é realizado só quando o modelo inclui erros estruturados. Sob a hipótese alternativa, a autorregressão dos erros é eliminada, e todos os *lags* da variável dependente e das causais são adicionados ao modelo. Se a hipótese nula é rejeitada, existe evidência de que um modelo mais geral deveria ser considerado, ao invés do modelo de Cochrane-Orcutt. O grande problema é descobrir em que direção deve-se generalizar o modelo corrente, e não existe uma resposta única para esta questão.

3.4.3 TESTES BASEADOS NA AUTOCORRELAÇÃO DOS RESÍDUOS¹¹

Como pode ser visto, o processo de construção de um modelo de regressão dinâmica deve levar em conta diversos diagnósticos com o objetivo de verificar se o modelo atual é apropriado. Em particular, deve-se sempre examinar o gráfico das autocorrelações dos resíduos. Se estas são significantes para alguns *lags*, alguma

¹¹ Podem ser feitos ainda testes para verificar a existência de variações na variância dos resíduos, ou seja, procura-se detectar a heterocedasticidade da série de resíduos.

característica da variável dependente não foi capturada pelo modelo atual. Por exemplo, no caso de dados mensais, se a autocorrelação dos resíduos é significante no *lag* 12, a observação situada num período genérico t-12 meses é relevante para explicar a observação no período t, e sua inclusão no modelo possivelmente resultará num decréscimo dos erros de previsão do modelo.

A existência de autocorrelações significantes nos resíduos pode então indicar uma das seguintes situações: 1) deve-se incluir mais *lags* da variável dependente ou 2) deve-se incluir *lags* adicionais das variáveis exógenas já presentes no modelo ou incluir novas variáveis causais.

Enfim, é importante saber que, em qualquer das situações mencionadas, o fato dos resíduos apresentarem autorrelações significantes indica que algum tipo de estrutura presente na série Y_t não foi captada pelo modelo em consideração.

Após o exposto, é importante salientar que toda esta metologia de Regressão Dinâmica será utilizada para estimar o modelo de previsão para o índice IPCA. A apresentação da base de dados utilizada e os resultados da previsão serão apresentados no próximo capítulo.

4 ANÁLISE DE DADOS E RESULTADOS

Neste capítulo será apresentada a base de dados utilizada. Posteriormente, serão apresentados os resultados da previsão realizada.

4.1 BASE DE DADOS

O dado da variável dependente utilizado neste trabalho se refere ao IPCA, divulgado pelo IBGE e pode ser obtido através da plataforma do Ipeadata. Nela são encontrados os dados distribuídos mensalmente a partir de janeiro de 2010 até agosto de 2025.

Conforme exposto no capítulo dois, serão analisados cinco índices para avaliação do impacto na variável dependente: o IGP-M, o câmbio, a taxa SELIC, o preço do petróleo (BRENT), o preço da energia elétrica e o nível do salário mínimo. Todos os índices foram obtidos através da plataforma Ipeadata e contemplam dados de janeiro de 2010 até agosto de 2025. A base foi construída forma de um histórico de índices para apresentarem a mesma base de comparação¹². A tabela 1 mostra, resumidamente, todas as variáveis que serão utilizadas para estimar o modelo.

¹² <https://www.ipeadata.gov.br/Default.aspx>

Tabela 1: Variáveis utilizadas no modelo

VARIÁVEL	TIPO DE VARIÁVEL	DESCRÍÇÃO
IPCA	DEPENDENTE	Índice Nacional de Preços ao Consumidor Amplo. É o índice oficial de inflação do Brasil, medindo a variação dos preços de produtos e serviços consumidos pelas famílias com renda entre 1 e 40 salários mínimos
PREÇO DO PETRÓLEO (BRENT)	EXPLICATIVA	Preço do barril de petróleo bruto extraído do Mar do Norte (Europa). Funciona como a referência internacional para a maioria das compras de petróleo no mundo.
NÍVEL DO SALÁRIO MÍNIMO	EXPLICATIVA	Representa o menor valor que um empregador pode pagar a um trabalhador no Brasil.
IGP-M (Índice Geral de Preços do Mercado)	EXPLICATIVA	Indicador de inflação mais amplo, que mede a variação de preços em diversas etapas da economia: atacado, consumidor e construção civil.
TAXA SELIC	EXPLICATIVA	Taxa básica de juros da economia brasileira. Serve como balizador para todas as outras taxas de juros (empréstimos, financiamentos, investimentos).
CÂMBIO	EXPLICATIVA	É o preço de uma moeda em relação a outra (nesse caso, do Real em relação ao Dólar).
PREÇO DA ENERGIA ELETRICA	EXPLICATIVA	Preço administrado que reflete custos de geração (hidrológica, termelétrica) e transmissão, além de encargos setoriais e impostos.

Fonte: Elaborado pelo autor.

4.2 A EQUAÇÃO DE PREVISÃO

Para realizar a projeção do índice do IPCA, foi utilizado o software Forecast Pro for Windows (FPW) para estimar o modelo. Para tal, foi aplicada a metodologia expressa no capítulo 3. Seguindo a estratégia *bottom-up*, ou seja, partindo de um modelo mais simples, aplicou-se os testes diagnósticos até chegar em um modelo mais elaborado.

Após realizadas todas as análises, foram desconsideradas as variáveis preço do petróleo, nível do salário mínimo, câmbio e preço da energia elétrica, pois não apresentaram significância nos testes de causalidade. Com isso a equação final do modelo pode ser expressa como:

$$\ln(\text{IPCA})_t = 0,03 + 0,14\ln(\text{IG})_t - 0,14\ln(\text{IG})_{t-1} + 0,01\ln(\text{SL})_t + 1,14\ln(\text{IPCA})_{t-1} - 0,42\ln(\text{IPCA})_{t-2} + \varepsilon_t \quad (4.1)$$

onde:

$\ln(\text{IPCA})_t$ = logneperiano do índice do IPCA em t

$\ln(\text{IG})_t$ = logneperiano do índice IGP-m em t

$\ln(\text{IG})_{t-1}$ = logneperiano do índice do IGP-M em t-1

$\ln(\text{SL})_t$ = logneperiano do índice da taxa Selic em t

$\ln(\text{IPCA})_{t-1}$ = logneperiano do índice do IPCA em t-1

$\ln(\text{IPCA})_{t-2}$ = logneperiano do índice do IPCA em t-2

ε_t = erro aleatório associado ao modelo

Vê-se que o modelo foi estimado na forma log-log para que os coeficientes possam ser analisados como coeficientes de elasticidade¹³. É importante ressaltar que todos os coeficientes estimados são significativos ao nível de significância de 5%. Pode-se inferir que 1% de aumento no índice do IGP-M, impacta num aumento de cerca de 0,14% no índice do IPCA. Já para um aumento de 1% no índice da taxa Selic, observa-se um aumento de cerca de 0,01% no índice do IPCA. Pode-se observar ainda a componente de dinâmica no modelo através da presença da própria

¹³ Para maiores detalhes ver Zanini (2000).

variável IPCA defasada em t-1 (maior coeficiente de regressão) e t-2. A variável defasada em t-1 com coeficiente igual a 1,14 reflete a tendência de alta nos meses anteriores.

Importante ressaltar que a escolha pela equação de Regressão Dinâmica é válida, pois ela modela a inflação brasileira como um fenômeno que possui inércia e transmissão de custos, o que está totalmente alinhado com o que a literatura acadêmica fala sobre a dinâmica de preços no país (LIBERGOTT, 2017; TABAJARA, 2016). A dependência do IPCA defasado (t-1 e t-2) é crucial para capturar a persistência inflacionária, que é uma marca histórica da economia brasileira, impulsionada pela indexação e pela forma como as expectativas são formadas (CARVALHO, 2014). A inclusão do IGP-M (t e t-1) reflete o mecanismo de repasse de preços do atacado para o consumidor, modelando, na prática, os choques de oferta e os custos de produção (MARTINEZ, 2011). Por fim, a Selic (t) reconhece o papel da política monetária, embora o sinal positivo no curto prazo possa indicar uma causalidade reversa ou que o efeito contracionista da taxa de juros só aparece de forma completa nos períodos seguintes (FREITAS JUNIOR, 2023).

Como pode ser observado na tabela 2, esse modelo de previsão tem o poder de explicação (R^2 ajustado) de 99,9% e o erro médio absoluto percentual (MAPE¹⁴) de apenas 0,19%. Em relação a fidedignidade estatística do modelo foi utilizado o teste de Ljung-Box sobre a estrutura de correlação dos resíduos dos modelos, obtendo a estatística de teste igual a 27,77. Por fim, verifica-se que o p-valor calculado para esta estatística apresenta um valor de 0,9344, aceitando a hipótese nula de erro descorrelatado¹⁵.

Tabela 2: Poder de Explicação e testes do modelo realizado

Indicadores	R^2 ajustado	MAPE
Valores	99,99%	0,19%

Fonte: Elaborado pelo autor.

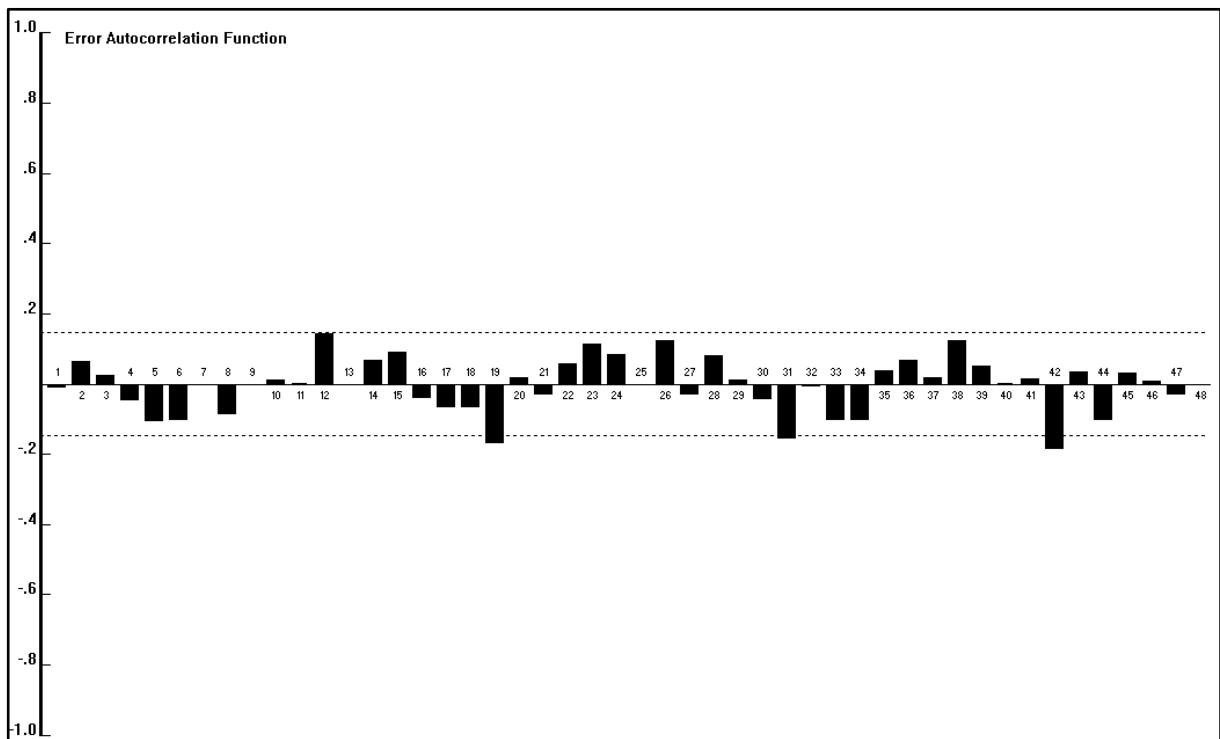
Além disso, na Figura 2 apresentada abaixo, observa-se a análise da função da autocorrelação dos erros, cujo resultado indica uma correlação fraca, próxima de zero (nota-se a autocorrelação dos erros na faixa entre -0,2 e 0,2). Com base nos

¹⁴ Erro médio que se comete ao se prever o próximo mês.

¹⁵ No FPW aceita-se a hipótese nula quando o p-valor for menor que o Nível de Confiança (NC).

resultados do teste e nos argumentos mencionados no parágrafo anterior, pode-se afirmar que o modelo estimado é estatisticamente fidedigno.

Figura 2: Autocorrelação dos erros



Fonte: Elaborado pelo autor.

Evidenciado o modelo e sua capacidade preditiva, na próxima seção são exibidos os resultados da projeção utilizando a equação apresentada na equação (4.1).

4.3 RESULTADOS DA PREVISÃO

Esta seção apresenta os resultados da previsão do IPCA obtidos a partir do modelo de Regressão Dinâmica. Conforme estabelecido nos modelos causais, a projeção da variável de interesse é dependente dos valores futuros das variáveis explicativas. Desse modo, os resultados aqui expostos refletem a aplicação da equação de previsão alimentada pelas autoprojeções geradas para os índices do IGP-M e taxa Selic.

A seleção do método de autoprojeção para as variáveis explicativas foi realizada por meio de uma competição de modelos entre o Método de Amortecimento

Exponencial e o Método de Box & Jenkins (MBJ). O MBJ foi o método selecionado por apresentar o melhor desempenho preditivo em uma análise recursiva fora da amostra¹⁶. Para selecionar o método vencedor, foram geradas previsões para diferentes horizontes de tempo, sendo escolhido aquele que minimiza o erro absoluto médio acumulado.

Após selecionado o MBJ, foi estimado para a série do IGP-M um modelo ARIMA(1,1,0) com transformação logarítmica. Já para a série da taxa Selic, foi estimado um modelo ARIMA(1,1,2)*(0,0,1) também com transformação logarítmica.

Sendo feita a autoprojeção das variáveis explicativas, pode-se calcular a projeção da variável de interesse (IPCA) para o ano de 2026. Como a base de dados possui informações até agosto de 2025, foi realizada a projeção para os meses de setembro de 2025 a dezembro de 2026, sendo considerados, portanto, 16 meses para a projeção. A tabela 3 apresenta os valores obtidos com a projeção para um intervalo de confiança de 95%.

¹⁶ Ver Goodrich (1999).

Tabela 3: Previsão do índice do IPCA para os próximos 16 meses

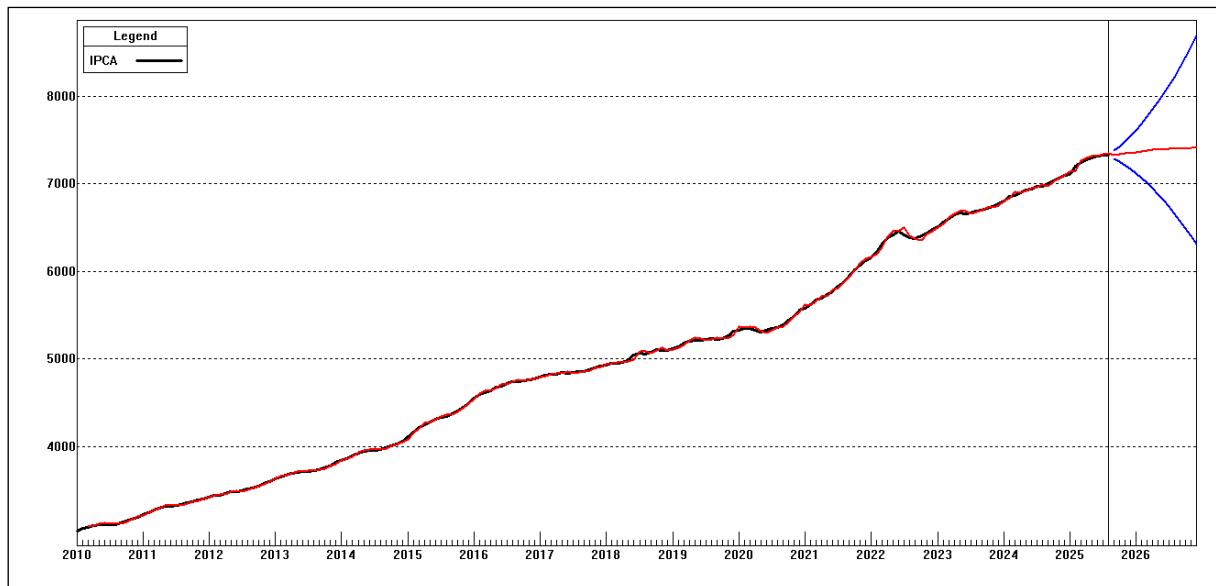
Data	Limite Inferior	Projeção	Limite Superior	Variação
set/25	7284,489	7330,354	7376,509	-
out/25	7251,370	7338,185	7426,039	0,107%
nov/25	7210,646	7344,065	7479,953	0,080%
dez/25	7166,070	7351,451	7541,626	0,101%
jan/26	7112,670	7354,685	7604,933	0,044%
fev/26	7067,711	7371,166	7687,649	0,224%
mar/26	7010,503	7379,041	7766,952	0,107%
abr/26	6948,323	7385,419	7850,012	0,086%
mai/26	6881,092	7389,830	7936,180	0,060%
jun/26	6810,758	7394,011	8027,213	0,057%
jul/26	6738,008	7398,426	8123,574	0,060%
ago/26	6658,988	7398,535	8220,216	0,001%
set/26	6577,023	7400,952	8328,099	0,033%
out/26	6492,059	7403,590	8443,106	0,036%
nov/26	6404,053	7405,917	8564,516	0,031%
dez/26	6313,850	7408,484	8692,895	0,035%

Fonte: Elaborado pelo autor. Nota: Intervalo de Confiança de 95%.

Analizando o gráfico da projeção (figura 3), é possível ver uma tendência de leve aumento do índice do IPCA para o período entre setembro de 2025 e dezembro de 2026, representando uma variação total de 1,07%. Este aumento está de acordo com a equação do modelo, onde se observa a variável de maior peso sendo o IPCA defasado do mês anterior ($t-1$), explicando a tendência do aumento do índice. Em contrapartida, verifica-se na equação de projeção a presença da variável do IPCA defasado em dois meses ($t-2$), que assume valores negativos, o que explica a suavização da curva de crescimento do índice.

Complementando a análise da curva de projeção, entre o mês de agosto de 2025 e outubro de 2025, o índice IGP-M sofreu uma variação positiva de 0,054%, conforme últimos dados divulgados pelo Ipeadata. Como essa variável tem impacto negativo na equação de projeção, pode ser observada uma pequena contribuição para a suavização da curva de crescimento do IPCA. Já a variável explicativa taxa Selic se manteve no patamar de agosto de 2025 (15,00%), o que indica que a influência deste índice sob a projeção se manteve igual durante o período citado.

Figura 3: Previsão para os próximos 16 meses do IPCA



Fonte: Elaborado pelo autor. Nota: Valores observados Valores ajustados/Previstos
 Intervalo de Confiança de 95%.

5 CONCLUSÃO

O Índice Nacional de Preços ao Consumidor Amplo (IPCA) é o indicador oficial de inflação no Brasil, sendo o principal instrumento usado por instituições públicas e privadas em seus planejamentos. Por isso, é necessário ter ferramentas que permitam análises antecipadas deste índice, auxiliando na tomada de decisão de diversos agentes na economia brasileira. Para tal, foi realizada a projeção do IPCA para o próximo ano, contemplando diversas variáveis que impactam direta ou indiretamente este índice.

As variáveis utilizadas para a construção do modelo de previsão para o IPCA foram apresentadas no segundo capítulo deste trabalho. Dentre elas, apenas duas (IGP-M e Taxa Selic) se mostraram significantes na estimativa do modelo. Com isso, as variáveis preço do petróleo, taxa de câmbio, preço da energia elétrica e nível do salário-mínimo foram desconsideradas.

Para atingir os objetivos deste trabalho, foi aplicado o Método de Regressão Dinâmica (MRD), chegando a uma equação de previsão que explica a série utilizada em 99,9%, obtendo um erro médio de previsão para o próximo mês de apenas 0,19%. De acordo com esta equação, 1% de aumento no IGP-M, impacta num aumento de cerca de 0,14% no IPCA. Já para um aumento de 1% na taxa Selic, observa-se um aumento de cerca de 0,01% no índice.

O MRD pode constituir uma ferramenta importante em estudos de séries temporais, pois combina a dinâmica da série dependente com a influência de variáveis explicativas. Neste trabalho foram utilizadas as autoprojeções das variáveis IGP-M e taxa Selic para obter uma previsão sobre o IPCA para os próximos 16 meses. Porém, é possível elaborar outros cenários de previsão a partir de diferentes variáveis, permitindo avaliar, através da equação de previsão, o impacto destas no índice.

A importância do IPCA para o Brasil vai além da política monetária, influenciando diretamente o mercado financeiro, as decisões de investimento e o planejamento. Para o mercado, o índice é importante para a precificação de ativos e a definição de taxas de juros de longo prazo. Para os investimentos, ele serve como referência para cálculo da rentabilidade real, e para o planejamento público e privado, é a base para reajustes contratuais e definição de metas.

Em conjunto com as projeções, a fim de antecipar tendências e a ajustar estratégias financeiras e de investimento, se faz necessário o acompanhamento contínuo de um conjunto de informações e relatórios sobre o IPCA. O monitoramento das notícias econômicas, como as decisões do Comitê de Política Monetária (COPOM) sobre a Taxa Selic, é fundamental. Além disso, a verificação dos relatórios oficiais do Banco Central (como o Boletim Focus) e do IBGE (divulgação mensal do índice) oferece uma visão detalhada das expectativas e dos componentes que influenciam o índice.

Por fim, este trabalho sugere o acompanhamento contínuo dos valores reais e o monitoramento da eficácia das previsões. Métodos alternativos como, por exemplo, os de Redes Neurais Artificiais também poderiam ser aplicados, bem como o desenvolvimento de modelos híbridos que combinem a linearidade de Métodos como os de Regressão Dinâmica com as não-linearidades das Redes Neurais Artificiais.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ARAÚJO, E. Padrões da transmissão cambial para taxa de inflação no Brasil. *Nova Economia*, Belo Horizonte, v. 33, n. 1, p. 1-28, 2023.

BCB. Relatório Focus. Disponível em: <https://www.bcb.gov.br/publicacoes/focus>. Acesso em: 12 nov. 2025

BARBOSA, L. M. Prevendo a Inflação Brasileira: Comparação Entre um Modelo Teórico e um Ateórico de Séries Temporais. *Informações Fipe*, São Paulo, 2019. Disponível em: <https://downloads.fipe.org.br/publicacoes/bif/bif462-44-49.pdf>. Acesso em: 27 out. 2025.

BRAGA, J. M. Estimação de um modelo desagregado de inflação de custo para o Brasil. *Ensaios FEE*, Porto Alegre, v. 37, n. 1, p. 123-150, 2016.

BRAGA, José Carlos de Souza. *A crise mundial e a economia brasileira*. São Paulo: Editora Contracorrente, 2011.

BRESSER-PEREIRA, Luiz Carlos. *Desenvolvimento e crise no Brasil: história, economia e política de Getúlio Vargas a Lula*. 5. ed. São Paulo: Editora 34, 2003.

CARVALHO, Fernando J. C. de. O Regime de Metas de Inflação no Brasil: uma análise empírica do ipca. Disponível em: <https://www.scielo.br/j/rec/a/QGwppNL8SgXxgHBRFBgnPvm/?format=pdf&lang=pt>. Acesso em: 08 nov. 2025

CARVALHO, A. R. A persistência da indexação no Brasil pós-Real. *Revista de Economia Política*, vol. 34, nº 2 (135), pp. 266-283, abril-junho/2014. Disponível em: <https://www.scielo.br/j/rep/a/TKZJSVmsRP9jjfmrxvDBh7f/?format=pdf&lang=pt>. Acesso em 09 nov. 2025

COCHRANE, D.; ORCUTT, G.H.. Application of Least Squares Regression to Relationships Containing Autocorrelated Error Terms. *Journal of the American Statistical Association*, 44, p. 32-61, 1949.

CONTADOR, Claudio R. Reflexões sobre o dilema entre inflação e crescimento econômico na década de 80. *Pesquisa e Planejamento Econômico*, Rio de Janeiro, v. 15, n. 1, p. 1-28, abr. 1985.

COELHO JR. Utilização do método Box-Jenkins para previsão de indicadores econômicos (IPCA, SELIC, Câmbio e Ibovespa). 2014. 21f. Monografia (Especialização em Macroeconomia e Finanças) – Setor de Ciências Sociais Aplicadas, Universidade Federal do Paraná, Curitiba, 2014

- DUDEWICZ, E.J.; MISHRA, S.N.. *Modern Mathematical Statistics*. Wiley, 1988.
- FEIJÓ, Ricardo; ARAÚJO, Eliane; BRESSER-PEREIRA, Luiz Carlos. Política monetária no Brasil em tempos de pandemia. Disponível em: <https://www.scielo.br/j/rep/a/5V8WcFdTxhzJV73ztc3mdBh/?format=pdf&lang=pt>. Acesso em: 09 nov. 2025
- FRANCO, Gustavo H. B. O Plano Real e a inflação. *Revista de Economia Política*, São Paulo, v. 15, n. 3, p. 5-23, jul./set. 1995.
- FREITAS, L. de; COSTA, H. K. de M.; SANTOS, E. M. dos. Efeitos do petróleo na inflação brasileira. *Caderno Pedagógico*, [S. I.], v. 22, n. 10, p. e19479, 2025. DOI: 10.54033/cadpedv22n10-286. Disponível em: <https://ojs.studiespublicacoes.com.br/ojs/index.php/cadped/article/view/19479>. Acesso em: 06 nov. 2025.
- FREITAS, Maria Cristina Penido de. Os efeitos da crise global no Brasil: aversão ao risco e preferência pela liquidez no mercado de crédito. *Revista Estudos Avançados* 23(66), 2009. Disponível em: <https://www.scielo.br/j/ea/a/dtdzn3ZzG7cQgyhfFnP6qHR/abstract/?lang=pt>. Acesso em: 05 nov. 2025
- FREITAS JUNIOR, A. Efeitos dos choques de política monetária sobre as taxas de inflação desagregadas: uma análise a partir de um TVP-VAR entre 2003 e 2020. *Revista de Economia Mackenzie*, São Paulo, v. 20, n. 1, p. 1-28, 2023.
- GIAMBIAGI, Fábio. *O Plano Real e Outros Ensaios*. Rio de Janeiro: Francisco Alves Editora, 2004.
- GIAMBIAGI, Fabio; ALÉM, Ana Cláudia. *Finanças públicas: teoria e prática no Brasil*. 4. ed. Rio de Janeiro: Campus/Elsevier, 2011.
- GONÇALVES, Reinaldo. *A década perdida: 1980-1990*. Rio de Janeiro: Forense Universitária, 1991.
- GOODRICH, R.L.; STELLWAGEN, E.A.. *Forecast Pro for Windows*. Business Forecast Systems, 1999.
- GUJARATI, D.N.. *Econometria Básica*. Campus, 2006.
- HAMILTON, J.D.. *Time Series*. Princeton, 1994.
- IBGE. Índice Nacional de Preços ao Consumidor Amplo (IPCA). Disponível em: <https://www.ibge.gov.br/explica/inflacao.php>. Acesso em: 07 nov. 2025.
- IBGE. Série Histórica IPCA. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/precos-e-custos/9256-indice->

[nacional-de-precos-ao-consumidor-amplo.html?t=series-historicas](https://naciona-de-precos-ao-consumidor-amplo.html?t=series-historicas). Acesso em: 05 nov. 2025.

IBGE. IPCA sobe 0,73% em dezembro e fecha 2021 em 10,06%. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/32724-ipca-sobe-0-73-em-dezembro-e-fecha-2021-em-10-06>. Acesso em: 29 out. 2025.

IPEADATA. IPCA - taxa de variação anual. Disponível em: <https://www.ipeadata.gov.br/ExibeSerie.aspx?module=m&serid=1410807112&oper=view>. Acesso em: 09 nov. 2025.

LIBERGOTT, J. M. Persistência Inflacionária no Brasil. 2017. Dissertação (Mestrado em Economia) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2017.

MARTINEZ, T. S. *Determinantes e desagregação do IPCA*. Texto para Discussão, n. 1658. Brasília, DF: Ipea, 2011.

MARTINEZ, T. S.; CERQUEIRA, V. S. Estrutura da inflação brasileira: determinantes e desagregação do IPCA. *Economia e Sociedade*, Campinas, v. 22, n. 2 (48), p. 409-456, ago. 2013. Disponível em: <https://www.scielo.br/j/ecos/a/yjKwPjkYXJc8GBk6cJcKHfM/abstract/?lang=pt>. Acesso em: 09 nov. 2025.

MODENESI, Andre de Melo; FERRARI FILHO, Fernando. Choque de oferta, indexação e política monetária: breves considerações sobre a aceleração inflacionária recente. *Revista Economia & Tecnologia*, [S. I.], v. 7, n. 3, 2011. DOI: 10.5380/ret.v7i3.26607. Disponível em: <https://revistas.ufpr.br/ret/article/view/26607>. Acesso em: 11 nov. 2025.

OREIRO, José Luis. A grande recessão brasileira: diagnóstico e uma agenda de política econômica. Disponível em: <https://www.scielo.br/j/ea/a/SxFbPNLxcStN6BKL7JTjtcT/abstract/?lang=pt#>. Acesso em: 11 nov. 2025

PRADO, Maria Clara. A real história do Plano Real. Rio de Janeiro: Record, 2005.

ROTTA, Edgard; LOPES, H. C.; ROSSINI, N. (Org.). O modelo de desenvolvimento brasileiro das primeiras décadas do século XXI: aportes para o debate. São Paulo: Hucitec, 2018.

SANTOS, C.; FERREIRA, R. T.; CASTELAR, I. Prevendo a inflação no Brasil com grande conjunto de dados: uma aplicação do modelo de fatores comuns. In: ENCONTRO DE ECONOMIA APLICADA, 2., 2016, Juiz de Fora. Anais [...], Juiz de Fora: UFJF, 2016.

SILVA, Maria Luiza Falcão. Plano Real e âncora cambial. *Revista de Economia Política*, São Paulo, v. 22, n. 3 (87), p. 3-24, jul./set. 2002. Disponível em: <https://www.scielo.br/j/rep/a/PbxtzNVZvNwcVcRVfdJqkgj/?lang=pt> Acesso em: 27 out. 2025.

TABAJARA, R. B. Inércia inflacionária no Brasil: uma análise do período pós-Plano Real até o ano de 2015. 2016. Monografia (Graduação em Ciências Econômicas) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016.

WEPPÓ, Gian L. C. Regime de metas de inflação no Brasil (1999–2020). 2021. Trabalho de Conclusão de Curso (Graduação em Ciências Econômicas) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2021.

ZANINI, A. Redes Neurais e Regressão Dinâmica: Um Modelo Híbrido para Previsão de Curto Prazo da Demanda de Gasolina Automotiva no Brasil. Rio de Janeiro, RJ, 28 de abril de 2000.