

UNIVERSIDADE FEDERAL DE MINAS GERAIS

Instituto de Ciências Exatas

Programa de Pós-Graduação em Estatística

**POLÍTICA MONETÁRIA BRASILEIRA: O CRÉDITO, MODELOS DE PREVISÃO E
A TAXA SELIC**

WALTER HORTA MOTTA FILHO

Belo Horizonte

2023

WALTER HORTA MOTTA FILHO

**POLÍTICA MONETÁRIA BRASILEIRA: O CRÉDITO, MODELOS DE PREVISÃO E
A TAXA SELIC**

Monografia apresentada ao Programa de Pós-Graduação em Estatística do Instituto de Ciências Exatas da Universidade Federal de Minas Gerais, como requisito parcial para obtenção do título de Especialista em Estatística.

Orientador: Professora Dra. Ela Mercedes Medrano de Toscano

Coordenador: Roberto da Costa Quinino

Belo Horizonte

2023

2023, Walter Horta Motta Filho.
Todos os direitos reservados.

Motta Filho, Walter Horta.

M921p Política monetária brasileira [recurso eletrônico]: o crédito, modelos de previsão e a taxa Selic / Walter Horta Motta Filho — 2023.
1 recurso online (70 f. il, color).

Orientadora: Ela Mercedes Medrano de Toscano
Monografia (especialização) - Universidade Federal de Minas Gerais, Instituto de Ciências Exatas, Departamento de Estatística
Referências: 68-70.

1. Estatística. 2. Análise de séries temporais. 3. Banco Central do Brasil. 4. Taxa de juros I. Medrano de Toscano, Ela Mercedes II. Universidade Federal de Minas Gerais. I. Instituto de Ciências Exatas, Departamento de Estatística. III. Título.

CDU 519.2 (043)

Ficha catalográfica elaborada pela bibliotecária Belkiz Inez Rezende Costa CRB 6/1510 -
Universidade Federal de Minas Gerais – ICEX



Universidade Federal de Minas Gerais

E-mail:

Instituto de Ciências Exatas

Tel: 3409-

9-5924

Departamento de Estatística

P Programa de Pós-Graduação / Especialização

Av. Pres. Antônio Carlos, 6627 - Pampulha

31270-901 - Belo Horizonte - MG

ATA DO 294º. TRABALHO DE FIM DE CURSO DE ESPECIALIZAÇÃO EM ESTATÍSTICA DE WALTER HORTA MOTTA FILHO.

Aos vinte e nove dias do mês de maio de 2023, às 08:00 horas, com utilização de recursos de videoconferência a distância, reuniram-se os professores abaixo relacionados, formando a Comissão Examinadora homologada pela Comissão do Curso de Especialização em Estatística, para julgar a apresentação do trabalho de fim de curso do aluno **Walter Horta Motta Filho**, intitulado: "Política monetária brasileira: o crédito, modelos de previsão e a taxa selic", como requisito para obtenção do Grau de Especialista em Estatística. Abrindo a sessão, a Presidente da Comissão, Professora Ela Mercedes Medrano de Toscano – Orientadora, após dar conhecimento aos presentes do teor das normas regulamentares, passou a palavra ao candidato para apresentação de seu trabalho. Seguiu-se a arguição pelos examinadores com a respectiva defesa do candidato. Após a defesa, os membros da banca examinadora reuniram-se sem a presença do candidato e do público, para julgamento e expedição do resultado final. Foi atribuída a seguinte indicação: o candidato foi considerado Aprovado condicional às modificações sugeridas pela banca examinadora no prazo de 30 dias a partir da data de hoje por unanimidade. O resultado final foi comunicado publicamente o candidato pela Presidente da Comissão. Nada mais havendo a tratar, a Presidente encerrou a reunião e lavrou a presente Ata, que será assinada por todos os membros participantes da banca examinadora. Belo Horizonte, 29 de maio de 2023.



Documento assinado digitalmente

ELA MERCEDES MEDRANO DE TOSCANO

Data: 30/05/2023 13:40:06-0300

Verifique em <https://validar.it.gov.br>

Prof.ª Ela Mercedes Medrano de Toscano (Orientadora)

Departamento de Estatística / ICEX / UFMG



Documento assinado digitalmente

SUELI APARECIDA MINGOTI

Data: 30/05/2023 17:46:53-0300

Verifique em <https://validar.it.gov.br>

Prof.ª Sueli Aparecida Mingoti

Departamento de Estatística / ICEX / UFMG

Roberto da Costa

Assinado de forma digital por

Quinino:808712917

Roberto da Costa

Quinino:80871291720

20

Dados: 2023.05.30 13:47:52

-0300

Prof. Roberto da Costa Quinino

Departamento de Estatística / ICEX / UFMG



Universidade Federal de Minas Gerais
Instituto de Ciências Exatas
Departamento de Estatística
Programa de Pós-Graduação / Especialização
Av. Pres. Antônio Carlos, 6627 - Pampulha
31270-901 – Belo Horizonte – MG

E-mail: pgest@ufmg.br
Tel: 3409-5923 – FAX: 3409-5924

DECLARAÇÃO DE CUMPRIMENTO DE REQUISITOS PARA CONCLUSÃO DO CURSO DE ESPECIALIZAÇÃO EM ESTATÍSTICA.

Declaro para os devidos fins que Walter Horta Motta Filho, número de registro 2020680275, cumpriu todos os requisitos necessários para conclusão do curso de Especialização em Estatística e que entregou para sua orientadora, a professora Ela Mercedes Medrano de Toscano, o trabalho, que aprovou a versão final. O trabalho foi apresentado no dia 29 de maio de 2023 com o título “Política monetária brasileira: o crédito, modelos de previsão e a taxa selic”.

Belo Horizonte, 21 de agosto de 2023

Roberto da Costa
Quinino:80871291720

Assinado de forma digital por
Roberto da Costa
Quinino:80871291720
Dados: 2023.08.21 14:51:54 -0300'

Prof. Roberto da Costa Quinino
Coordenador do curso de
Especialização em Estatística
Departamento de Estatística / UFMG

RESUMO

Este trabalho tem como objetivo realizar a previsão para o Saldo de Crédito, divulgado pelo Banco Central do Brasil (BCB), e verificar a relação entre o crédito e a taxa básica de juros. Para a previsão, foram estimados modelos univariados por meio da metodologia Box-Jenkins. A relação crédito/taxa de juros foi estimada por regressão dinâmica considerando também a própria variável dependente como regressora. A previsão do saldo de crédito é importante para compreender os impactos da Política Monetária na economia.

Palavras-chaves: Saldo de Crédito, Séries Temporais, Banco Central, Taxa Selic, Box-Jenkins, Regressão Dinâmica.

ABSTRACT

This work aims to forecast the Credit Balance, released by the Central Bank of Brazil (BCB), and verify the relationship between credit and the basic interest rate. For forecasting, univariate models were estimated using the Box-Jenkins methodology. The credit/interest rate relationship was estimated by dynamic regression, also considering the dependent variable as a regressor. The forecast of the credit balance is important to understand the impacts of Monetary Policy on the economy. Additionally, these forecasts can be incorporated into other predictive models, such as GDP.

Keywords: Credit Balance, Time Series, Central Bank, Selic Rate, Box-Jenkins, Dynamic Regression.

Lista de Figuras

Figura 1 - Síntese dos Mecanismos de Transmissão da Política Monetária	17
Figura 2 - Evolução da Razão Crédito/PIB no Brasil	19
Figura 3 - Evolução da Razão Crédito/PIB no Brasil	19
Figura 4 - Evolução da Composição do Crédito	21
Figura 5 - Taxas de Juros SELIC, TJLP e TLP.....	22
Figura 6 - Evolução da meta de inflação e da inflação corrente	23
Figura 7 - Evolução da Taxa Selic	23
Figura 8 - Diagrama de Dispersão.....	29
Figura 9 – Exemplo correlogramas FAC e FACP modelo AR (1).....	33
Figura 10 - Exemplo correlogramas FAC e FACP modelo MA (1).....	34
Figura 11 - Exemplos de correlogramas FAC e FACP - ARMA (1,1)	35
Figura 12 - Série histórica do estoque de crédito – em logaritmo	46
Figura 13 - Concessão de Crédito por trimestre.....	46
Figura 14 - Aplicando uma diferença simples e uma sazonal	47
Figura 15 - Correlogramas FAC e FACP da série diferenciada.....	47
Figura 16 – Resultados Teste de Raiz Unitária de Dickey-Fuller	48
Figura 17 - Resultados da Estimação – Modelo 1	49
Figura 18 - Valores ajustados da série – Modelo 1.....	49
Figura 19 - Correlogramas FAC e FACP dos Resíduos – Modelo 1.....	50
Figura 20 - Distribuição dos Resíduos – Modelo 1	50
Figura 21 – Histograma e QQ Plot dos Resíduos – Modelo 1	51
Figura 22 - Resultados da Estimação - Modelo 2	51
Figura 23 - Resultados da Estimação - Modelo 3	52
Figura 24- Valores ajustados da série – Modelo 3.....	53
Figura 25 - Correlogramas FAC e FACP dos Resíduos – Modelo 3.....	53
Figura 26 - Distribuição dos Resíduos – Modelo 3	54
Figura 27 - Histograma e QQ Plot dos Resíduos – Modelo 3	54
Figura 28 – Estoque de Crédito e Valores Ajustados.....	56
Figura 29 - Previsão do estoque de crédito.....	56
Figura 30 - Taxa Selic e Log do Saldo da Carteira de Crédito Nacional	58
Figura 31 - Resultados da regressão do Modelo 4	59
Figura 32 - Teste de Durbin-Watson do Modelo 4	59
Figura 33 - Distribuição dos Resíduos	59

Figura 34 - FAC e FACP dos Resíduos	60
Figura 35 - Resultados da regressão Modelo 5.....	61
Figura 36 - Teste de Durbin-Watson do Modelo 5	61
Figura 37 - Distribuição dos Resíduos - Modelo 5	62
Figura 38 - FAC e FACP dos Resíduos	62
Figura 39 - Resultados do Modelo 6	63
Figura 40 - Teste de Durbin-Watson do Modelo 6	63
Figura 41 - FAC e FACP dos Resíduos	64

Lista de Tabelas

Tabela 1 - Variáveis Utilizadas	29
Tabela 2 - Análise do resultado da inflação da variância – FIV	42
Tabela 3 - Testes de Normalidade e Autocorrelação dos resíduos – Modelo 1.....	51
Tabela 4 - Testes de Normalidade e Autocorrelação dos resíduos – Modelo 3.....	55
Tabela 5 - Resultados Modelos Saldo das Operações de Crédito.....	55
Tabela 6 - Valores reais e previstos do estoque de crédito.....	57
Tabela 7 - Estatística dos Erros de Previsão	57

Sumário

1 INTRODUÇÃO	12
2 REVISÃO DA LITERATURA EMPÍRICA	14
2.1 Política Monetária e seus mecanismos de transmissão	15
2.2 Política Monetária no Brasil.....	17
2.3 A segmentação e a evolução do mercado de crédito brasileiro.....	20
2.4 Evolução da inflação e dos juros no Brasil	22
2.5 A hipótese de aumento na potência da política monetária brasileira: o problema e sua importância.....	25
4 OBJETIVOS	28
4.1 Objetivo geral.....	28
4.2 Objetivos específicos	28
5 METODOLOGIA	28
5.1 Base de Dados e Descrição das variáveis	28
5.2 Metodologia	30
5.2.1 Séries temporais – aspectos gerais	30
5.2.2 Modelos ARMA	32
5.2.2.1 Processo Autorregressivos (AR).....	32
5.2.2.2 Processo Média Móvel (MA)	33
5.2.2.3 Modelos Autorregressivos e de Médias Móveis - ARMA.....	35
5.2.2.4 Função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACP).....	37
5.2.3 A metodologia Box-Jenkins.....	38
5.2.3.1 Verificação de modelos ARMA(p,q)	38
5.2.3.2 Escolha dos modelos.....	40
5.2.3.3 Previsão	40
5.2.4 Regressão Dinâmica.....	41
5.2.5 Análise dos Resíduos	43
6 ANÁLISE DE RESULTADOS	45

6.1 Análise da Série.....	45
7 CONCLUSÃO	65
9 REFERÊNCIAS.....	66

1 INTRODUÇÃO

De acordo com o Fundo Monetário Internacional (FMI), cerca de 84% dos países deverão registrar inflação mais baixa em 2023. A inflação global deverá recuar de 8,8%, em 2022, para 6,6%, em 2023, e para 4,3%, em 2024, reflexo, principalmente, dos impactos da alta dos juros na maioria dos países. Ainda assim, o Fundo Monetário Internacional (FMI) projeta que os níveis de inflação permanecerão acima do patamar pré-pandemia em pelo menos 86% dos países. Esse cenário seria consistente com a permanência das taxas de juros mundiais em patamares mais elevados.

No Brasil, de acordo com o Boletim Focus do Banco Central do Brasil (2023), a inflação deverá alcançar 5,9%, em 2023, patamar superior ao observado em 2022 (5,8%) e acima do intervalo de tolerância de 3,25% + 1,5 ponto percentual (p.p) estipulada pelas autoridades. Por sua vez, a taxa básica de juros deverá encerrar 2023 entre as maiores do mundo (12,75% ao ano).

Desde 1999, o Brasil está entre os países que adotaram o Regime de Metas de Inflação. Nesse regime, o Banco Central (Bacen) persegue uma meta de inflação previamente estabelecida pelo Conselho Monetário Nacional (CMN), com tolerância de 1,5 p.p para mais ou para menos. Entre as principais características desse regime está a utilização da taxa de juros Selic como principal instrumento de política monetária no controle da inflação.

Historicamente a taxa básica de juros brasileira está entre as maiores do mundo, mesmo se comparado a outros países emergentes. Em um estudo do FMI, Segura-Ubierno (2012), enumera cinco grupos de fatores que explicam a taxa de juros mais elevada no Brasil: (i) a situação fiscal; (ii) o baixo nível de poupança doméstica; (iii) instituições fracas; (iv) histórico de inflação elevada e volátil; e (v) fatores que obstruem os mecanismos de transmissão da política monetária.

Os mecanismos de transmissão da política monetária são os canais pelos quais a variação na taxa básica de juros influencia o nível de atividade econômica e, portanto, o nível de inflação.

De acordo com FRAGUAS (2014), no Brasil, o Banco Central dá ênfase a cinco mecanismos de transmissão: as taxas de juros; a taxa de câmbio; o preço dos ativos; as expectativas e o crédito.

As taxas de juros seriam reflexo do efeito da política monetária no lado real da economia; uma contração na oferta de moeda, após aumento da Taxa Básica de Juros, resultaria em elevação das demais taxas de juros do mercado e um recuo nos investimentos, no produto e, conseqüentemente, nos preços.

O mecanismo de transmissão via crédito teria os bancos comerciais como principais executores. A elevação da taxa básica de juros resultaria em aumento nas taxas de juros dos financiamentos para pessoas físicas e jurídicas, o que desestimularia a concessão de novos financiamentos. A redução dos financiamentos, por sua vez, implicaria em queda no consumo, no investimento e, conseqüentemente, na atividade econômica e no nível de preços.

Vale ressaltar, entretanto, que o canal do crédito tem sua eficácia obstruída pelas características do mercado de crédito brasileiro. Esse mercado é segmentado entre as modalidades livre e direcionado. No primeiro, as taxas de juros se ajustam livremente de acordo com as variações da taxa Selic. No segundo, elas são estipuladas por políticas de governo, sendo menos afetadas por variações da taxa básica de juros e, portanto, menos influenciadas pela política monetária. São exemplos desse mercado os financiamentos relacionados ao segmento imobiliário no âmbito do Sistema Financeiro de Habitação (SFH), as linhas de crédito agrícola e as operações do Banco Nacional de Desenvolvimento Econômico e Social (BNDES). De acordo com o Banco Central (2020), o volume de crédito direcionado no crédito total avançou de 38,4%, em 2010, para 49,2%, em 2015, patamar recorde para a série histórica. Por sua vez, de 2015 a 2019, o volume de crédito direcionado recuou para 42,1%.

A parcela relevante do crédito direcionado no crédito total impõe obstáculos à transmissão de política monetária, reduzindo a capacidade do Banco Central em atingir seus objetivos. Conseqüentemente, essa realidade seria compatível com a necessidade de o Banco Central adotar taxas de juros mais elevadas para manter a inflação mais baixa (Barboza, 2015).

Há uma vasta literatura sobre a obstrução do canal de transmissão do crédito na política monetária brasileira. Bonomo e Martins (2016) encontraram evidências de que os financiamentos realizados por bancos estatais respondem menos a choques de aumento de juros em comparação aos bancos privados. Rizzo (2018) argumenta

que as políticas de crédito direcionado produzem impacto negativo na eficácia da política monetária, explicando, desse modo, os juros mais elevados no país. Por sua vez, Barboza (2015) argumenta que a baixa importância do crédito livre na determinação da demanda agregada (consumo e investimento), entre outros fatores, exigiria um maior nível de taxas de juros para que o Bacen possa cumprir com o objetivo de manter a inflação na meta.

Nos últimos anos, algumas transformações no mercado de crédito e de capitais no Brasil trouxeram a discussão sobre o possível aumento na potência da política monetária brasileira. De acordo com o Banco Central (2020), o crédito bancário passou por mudanças que tenderiam a aumentar o potencial da política monetária: redução do volume de crédito direcionado e maior participação do crédito livre no crédito total; e mudanças na taxa de juros utilizada pelo BNDES. Essa última ocorreu em 2018, quando houve a substituição da Taxa de Juros de Longo Prazo (TJLP) pela Taxa de Longo Prazo (TLP). Essa nova taxa seria mais sensível às variações na taxa básica de juros do Banco Central.

Com o objetivo de contribuir para as discussões sobre possíveis mudanças no potencial da política monetária brasileira em relação às recentes alterações, este estudo visa realizar a previsão do saldo de crédito para os próximos trimestres e analisar a relação entre a oferta de crédito e a Taxa Selic no período compreendido entre o primeiro trimestre de 2000 e o quarto trimestre de 2022. Para alcançar esse objetivo, serão utilizados dados fornecidos pelo Banco Central, que apresentam a evolução do saldo da carteira de crédito total. A metodologia utilizada será o método de Box e Jenkins para identificação de modelos que acompanhem a variabilidade da série e apresentem boa capacidade de previsão do estoque de crédito nos trimestres a frente.

O estudo é organizado da seguinte forma: na seção 2, uma revisão dos estudos sobre o tema e suas conclusões; na seção seguinte (3), a metodologia, variáveis e modelo econométrico utilizados; na seção 4, os objetivos específicos; na seção 5, os resultados; e, por fim, na seção 6, as principais conclusões do estudo.

2 REVISÃO DA LITERATURA EMPÍRICA

Pretende-se nesta seção apresentar um resumo teórico sobre política monetária e seus canais de transmissão; o contexto brasileiro; a evolução da inflação

e dos juros; e a literatura empírica acerca da revisão na potência da política monetária brasileira.

2.1 Política Monetária e seus mecanismos de transmissão

Para Taylor (1995), os mecanismos de transmissão são os processos pelos quais as decisões de política monetária afetam a demanda agregada e a inflação. Essas decisões podem ser modeladas pela mudança da taxa de juros de curto prazo por parte do Banco Central. Alterações na taxa de juros afetariam variáveis como a oferta de crédito, a riqueza, a renda, a taxa de câmbio e o custo do capital. Conseqüentemente, o produto real e nível de preços são influenciados por meio dessa dinâmica (MEURER e TOMAZZIA, 2009).

Taylor (1995) define que uma alteração na taxa de juros de curto prazo produz uma alteração na taxa de câmbio e na taxa de juros de longo prazo. Essas alterações trariam impacto para a demanda agregada (consumo, investimento e exportações líquidas). Em um segundo momento, os salários e os preços dos bens começariam a ajustar-se a alterações nessas variáveis de demanda agregada. Essa seria então a conexão entre taxa de juros, a taxa de câmbio, a demanda agregada e a inflação.

Barboza (2015), enumera cinco mecanismos de transmissão da política monetária: (i) canal de crédito; (ii) canal do valor dos ativos; (iii) câmbio; (iv) canal das taxas de juros; e (v) canal das expectativas.

O canal do crédito conecta a política monetária na direção da economia real. A elevação da taxa básica de juros resultaria em aumento nas taxas de juros dos financiamentos para pessoas físicas e jurídicas, desestimulando a contratação de dívidas por parte das famílias e das empresas, seja para consumo ou investimento.

O canal de valor dos ativos seria a relação entre a política monetária e o mercado de capitais. Ele traduz o comportamento do consumidor por meio do efeito riqueza; a elevação dos juros tornaria os títulos de renda fixa mais vantajosos em relação ao mercado de renda variável. Conseqüentemente, haveria recuo nos preços das ações. Aquelas famílias que possuísem parte dos recursos aplicados no mercado de capitais teriam um recuo no valor dos investimentos (riqueza) e, portanto, tenderiam a consumir menos, resultando no recuo do PIB. Para Minella (2002) esse mecanismo não seria tão eficaz no Brasil, onde a maior parte da população não mantém seus recursos financeiros no mercado de ações.

Por sua vez, o canal de taxa de câmbio é importante em economias abertas, que possuem taxa de câmbio flutuante e livre movimentação de capitais, que transmitem os impulsos monetários de duas maneiras distintas: (1) alteração nas exportações líquidas (exportações – importações) e (2) via alteração no preço dos bens comercializáveis internacionalmente. De acordo com Barboza (2015), a movimentação na taxa básica de juros altera o diferencial entre os juros interno e externo, atraindo ou expulsando capitais. Esse movimento de capitais influencia a taxa de câmbio nominal e real. Conseqüentemente, a taxa de câmbio atua para o avanço ou redução das exportações líquidas. O recuo nas exportações líquidas contribui para a queda do PIB, ao passo que avanços nas exportações líquidas contribuem para o crescimento do PIB. Esse mecanismo também foi citado por Taylor (1995).

Já as alterações no preço dos bens comercializáveis teriam influência direta sobre a inflação. Ela ocorreria da seguinte maneira: a elevação na taxa de juros e, conseqüentemente, a valorização da taxa de câmbio, reduz o preço doméstico de bens e serviços importados, reduzindo inclusive o preço de insumos importados para processos produtivos nacionais.

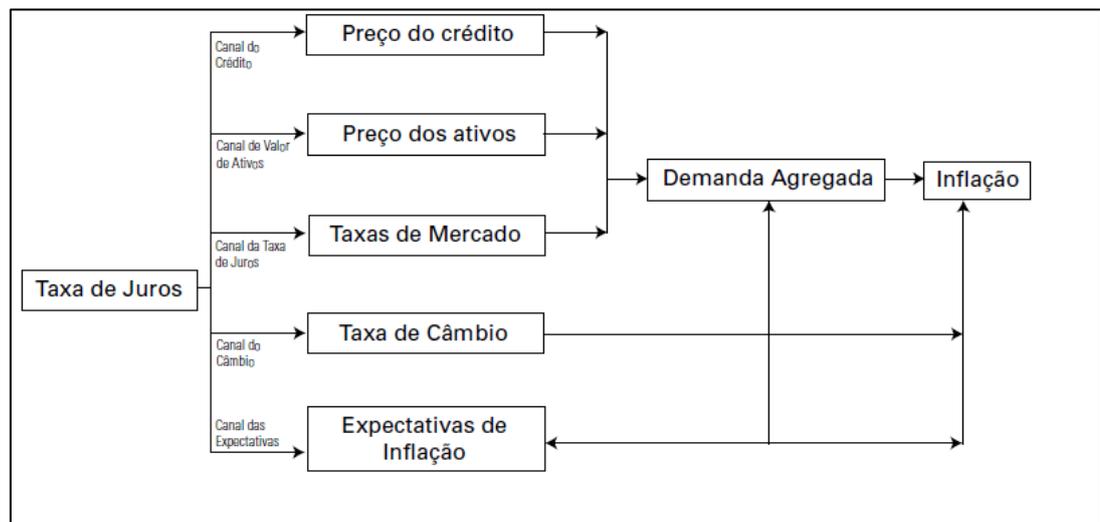
O canal das taxas de juros leva em consideração a existência de uma estrutura a termo das taxas de juros. Essa estrutura compreende a relação entre as taxas de juros de títulos com mesmo grau de risco, mas datas de vencimentos diferentes. Alterações na taxa básica de juros de curto prazo teria reflexos em taxas de juros de prazos mais longos. Nesse sentido, investimentos que se financiam com juros de longo prazo também seriam afetados por alterações na taxa básica de juros de curto prazo.

Já o canal das expectativas de inflação tem grande importância na dinâmica inflacionária. Barboza (2015) enumera três atuações distintas das expectativas de inflação sobre o processo de formação de preços: (i) diretamente, pela sua incorporação aos preços dos bens e serviços; (ii) pelos salários, já que são incorporados às negociações de reajustes, representando importante item para o custo das empresas e; (iii) diretamente, alterando a taxa de juros real ex-ante (juro nominal descontado da taxa esperada de inflação).

De acordo com Muinhos (2001), a principal característica do Regime de Metas de Inflação se dá pela atuação do Bacen em olhar as expectativas de inflação futura para decidir os juros de curto prazo.

Vale ressaltar que, normalmente, as expectativas de inflação possuem respostas inversamente proporcionais a alteração na taxa básica de juros, isto é, aumento de taxa de juros reduz a expectativa de inflação futura e vice-versa.

Figura 1 - Síntese dos Mecanismos de Transmissão da Política Monetária



Fonte: Barboza (2015).

2.2 Política Monetária no Brasil

Desde 1999 o Brasil adota o regime de Metas para a Inflação, no qual o Bacen assume o compromisso de garantir que a inflação efetiva esteja em linha com uma meta pré-definida e anunciada publicamente (FRAGUAS, 2014). A vantagem desse regime, de acordo com Freitas e Muinhos (2001) é a forma transparente e, conseqüentemente, o ganho de credibilidade na capacidade do Banco Central de manter o poder de compra da moeda.

No regime de metas para a inflação brasileiro, o Conselho Monetário Nacional (CMN) define uma meta para a variação do nível de preços e o Banco Central utiliza instrumentos para cumprir esse objetivo. O Banco se orienta e toma decisões por meio do seu Comitê de Política Monetária (Copom) – órgão responsável por acompanhar a tendência futura de preços e determinar alterações da taxa básica de juros em caso

de desvios da inflação da meta. A taxa básica de juros no Brasil é chamada de Taxa Selic.

O Copom considera os mecanismos de transmissão explicitados na seção anterior, a saber: (i) câmbio; (ii) taxas de juros; (iii) expectativas; (iv) valor dos ativos; e (v) crédito.

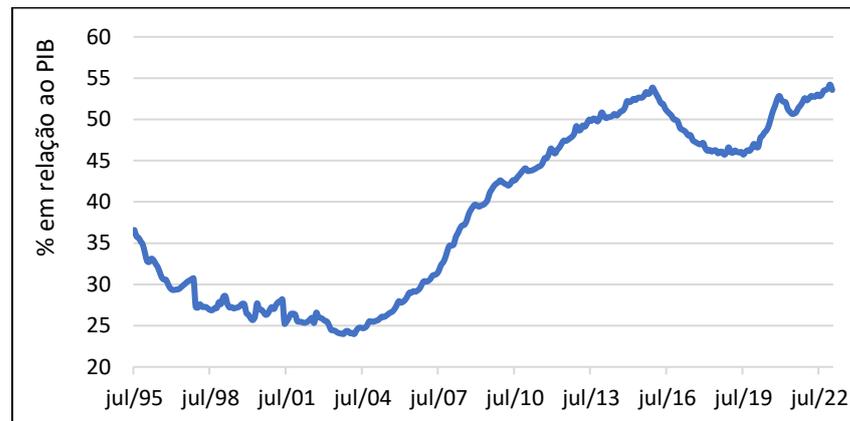
No Brasil, o efeito dos aumentos das taxas de juros na demanda agregada (consumo e investimento) leva de dois a três trimestres. O impacto da demanda agregada no PIB leva mais três trimestres adicionais para gerar efeitos na inflação (Bogdanski, Tombini e Werlang, 2000).

O canal do câmbio passou a ter maior importância após o país adotar o regime de câmbio flutuante, em 1999. De acordo com o Banco Central (2007), o canal tende a operar com menos defasagem em relação ao canal de juros. As variações na taxa básica de juros alteram os rendimentos dos títulos domésticos em relação aos títulos externos, influenciando o fluxo de capitais e, conseqüentemente, a taxa de câmbio. Essa, por sua vez, afeta o preço dos produtos comercializáveis e, portanto, a inflação. Para (Marcatti, 2011) a defasagem, nesse caso, dependerá da percepção dos agentes sobre quão persistente será a o nível do câmbio pós variação cambial.

Bevilaqua et al. (2007) argumenta que as expectativas exercem papel importante na política monetária brasileira desde a implantação do Regime de Metas para a Inflação.

O canal do crédito ganhou relevância ao longo do regime de metas. Bogdanski, Tombini e Werlang (2000) argumentaram que, devido à baixa participação do crédito na economia, esse canal era inoperante e negligenciável até os anos 2000. Contudo, esse canal se tornou mais relevante na medida em que houve avanço do crédito como proporção do PIB. Sobrinho (2003) aponta que o canal de crédito é atuante no país. Para Coelho, de Mello e Garcia (2010), o poder da política monetária via crédito tem crescido com o passar dos anos.

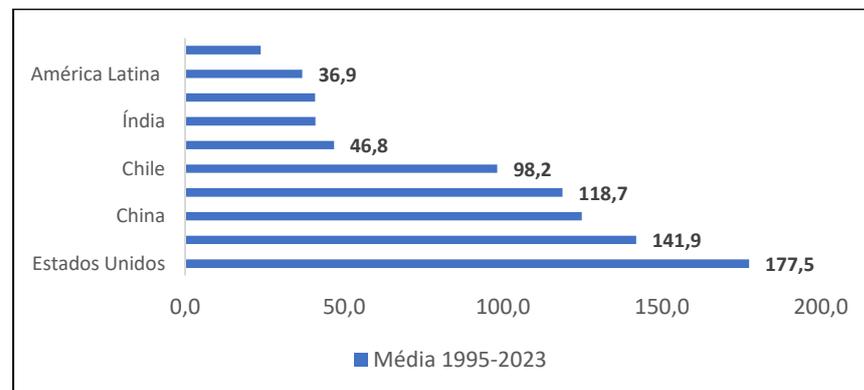
Figura 2 - Evolução da Razão Crédito/PIB no Brasil



Fonte: Elaborado pelo autor (2023), dados do BCB.

A participação do crédito como proporção do PIB cresceu a partir de 2004, saindo de 24% para 53%, em 2023. Ainda assim, comparativamente a outros países, a razão crédito/PIB é baixa. Na Figura 3 é possível observar o tamanho do mercado de crédito brasileiro em comparação a alguns países e regiões. Apesar de possuir uma participação maior que a média da América Latina e Caribe, ela é mais baixa do que em países como Chile, África do Sul, China e Estados Unidos.

Figura 3 - Evolução da Razão Crédito/PIB no Brasil



Fonte: Elaborado pelo autor (2023), dados do Banco Mundial.

Ainda que a participação do crédito na economia tenha crescido no país, destacam-se as distorções presentes em sua composição. Elas geram uma série de peculiaridades que alteram o funcionamento e eficiência da política monetária. De acordo com Barboza (2015), podemos citar as seguintes distorções no mercado de crédito brasileiro: (i) segmentação, com elevada participação do crédito direcionado; (ii) baixa penetração do crédito livre na determinação da renda, (iii) e truncada

estrutura a termo das taxas de juros. O autor também cita mais dois fatores que obstruem outros canais de transmissão: (i) a participação das Letras Financeiras do Tesouro (LFT's) na composição da dívida pública e (ii) a participação dos preços administrados na composição do índice de preços (IPCA).

A elevada participação das LFT's na composição da dívida pública caracteriza uma obstrução ao canal de transmissão do valor dos ativos, sendo títulos pós-fixados, que possuem elasticidade nula do seu preço em relação à taxa de juros. Ou seja, variações na Selic não trariam a percepção de variações na riqueza e no valor dos ativos. Para Loyo (2006) apud Barboza (2015), a elevação da taxa Selic aumenta os fatores de desconto das LFT's de um lado, mas eleva os rendimentos na mesma proporção, de outro lado, tornando nulo o efeito riqueza.

No que se refere aos preços administrados, os reajustes de produtos como combustíveis; medicamentos; água e eletricidade precisam de autorização do governo. Essa característica faz com que uma parte da composição do índice de preços seja insensível às condições de oferta e demanda e, conseqüentemente, à política monetária (Barboza, 2015).

2.3 A segmentação e a evolução do mercado de crédito brasileiro

A carteira de crédito do Sistema Financeiro Nacional pode ser dívida em dois grupos: o crédito livre e o crédito direcionado. De acordo com Rizzo (2018), a oferta de crédito no país é realizada em sua maioria pelo crédito direcionado. Esse tipo de crédito pode ser decomposto em três grupos:

- (i) Habitacional;
- (ii) Rural;
- (iii) Empréstimos concedidos pelo Banco Nacional de Desenvolvimento Econômico e Social (BNDES)

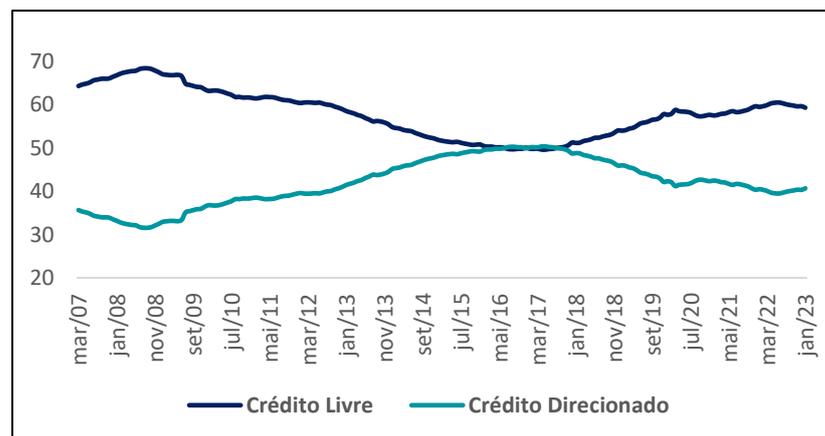
De acordo com Barboza (2011) apud Lundberg (2011), a oferta dessas três modalidades de crédito é realizada por três grandes bancos públicos. A concessão de créditos voltados para financiamentos empresariais é feita, em grande parte, por meio das operações do BNDES. Já a liberação de financiamentos habitacionais ocorre, em maior parte, no âmbito do Sistema Financeiro Habitacional, sendo a Caixa Econômica Federal a principal instituição financiadora. Por fim, o crédito rural está a cargo do

Sistema Nacional de Crédito Rural, e o Banco do Brasil é a principal instituição financiadora.

O crédito direcionado se caracteriza pelas suas taxas de juros inferiores as taxas praticadas no segmento de crédito livre. Para Schwartzman (2011), “o nível de Taxa Selic afeta menos a demanda agregada privada doméstica do que faria na ausência do crédito direcionado”. Essa característica representa uma obstrução ao canal de transmissão via crédito no Brasil, tornando menos eficiente a política monetária do Banco Central.

A literatura sobre a obstrução do canal de crédito no país é vasta e abrangente. Bonomo e Martins (2016) encontraram evidências de que os financiamentos realizados por bancos estatais respondem menos a choques de aumento de juros em comparação aos bancos privados. Rizzo (2018) argumenta que as políticas de crédito direcionado produzem impacto negativo na eficácia da política monetária, explicando, desse modo, os juros mais elevados no país. Por sua vez, Barboza (2015) argumenta que a baixa importância do crédito livre na determinação da demanda agregada (consumo e investimento), entre outros fatores, exigiria um maior nível de taxas de juros para que o Bacen possa cumprir com o objetivo de manter a inflação na meta.

Figura 4 - Evolução da Composição do Crédito

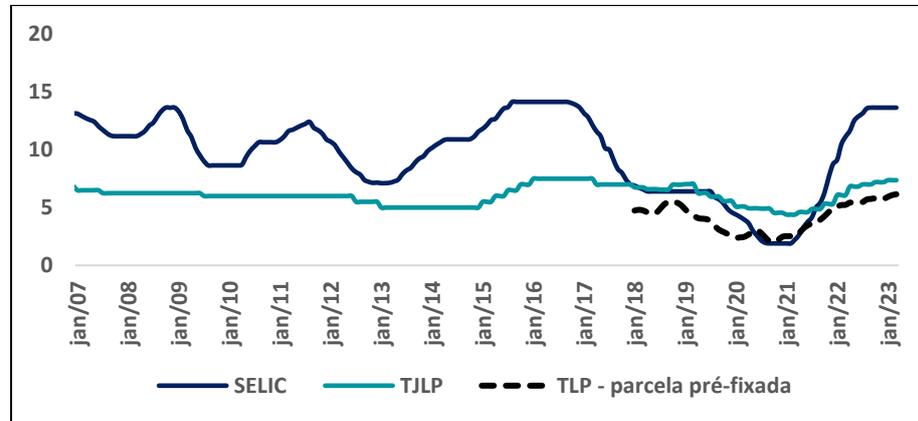


Fonte: Elaborado pelo autor (2023), dados do BCB.

O volume de crédito direcionado na carteira de crédito total no país avançou de 35,3% para 50,2% entre 2007 e 2017, conforme exposto na Figura 4. Esse período coincidiu com a política de fixação da Taxa de Juros de Longo Prazo (TJLP) – utilizada pelo BNDES, em níveis praticamente estáveis, não respondendo aos movimentos da

Taxa Selic. Entre 2007 e 2017, a Selic média ficou em 11%, enquanto a TJLP marcou média de 6,1%.

Figura 5 - Taxas de Juros SELIC, TJLP e TLP



Fonte: Elaborado pelo autor (2023), dados do BCB.

Duas importantes mudanças ocorreram no mercado de crédito brasileiro nos últimos anos: o avanço do crédito livre na carteira de crédito total e a mudança na taxa de juros utilizado pelo BNDES nas concessões de financiamentos.

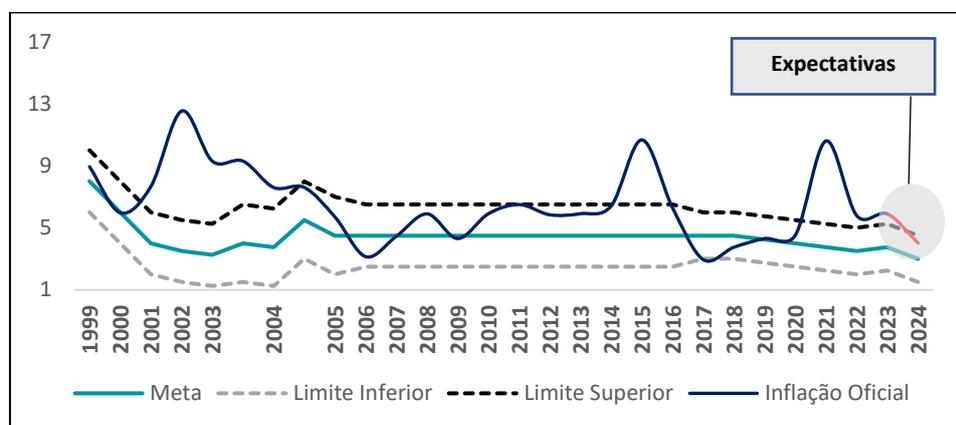
A partir de 2018, por meio da Lei nº 13.483, as operações do BNDES passaram a contar com a Taxa de Juros de Longo prazo (TLP) como remuneração. O cálculo da TLP considera a variação do IPCA e uma taxa de juros pré-fixada, estabelecida em cada operação. Essa taxa pré-fixada corresponde à média aritmética simples das taxas relativas aos vértices de cinco anos da estrutura a termo da taxa de juros das Notas do Tesouro Nacional, Série B (NTN-B), apuradas diariamente pelos três meses que antecedem sua definição. Nesse sentido, a taxa média das operações apuradas pela TLP tem seguido de maneira mais próxima aos movimentos da taxa Selic (Figura 5), o que pode contribuir para uma maior sensibilidade do crédito a variações na taxa básica de juros.

2.4 Evolução da inflação e dos juros no Brasil

As metas de inflação no Brasil são estabelecidas pelo Conselho Monetário Nacional (CMN), órgão composto pelo Presidente do Banco Central, pelo Ministro do Planejamento e pelo Ministro da Fazenda. A meta é fixada normalmente em junho do ano t para a inflação do ano $t+2$. Há uma meta central para a inflação e um intervalo – banda – de tolerância para mais ou para menos, utilizado para acomodar choques na economia.

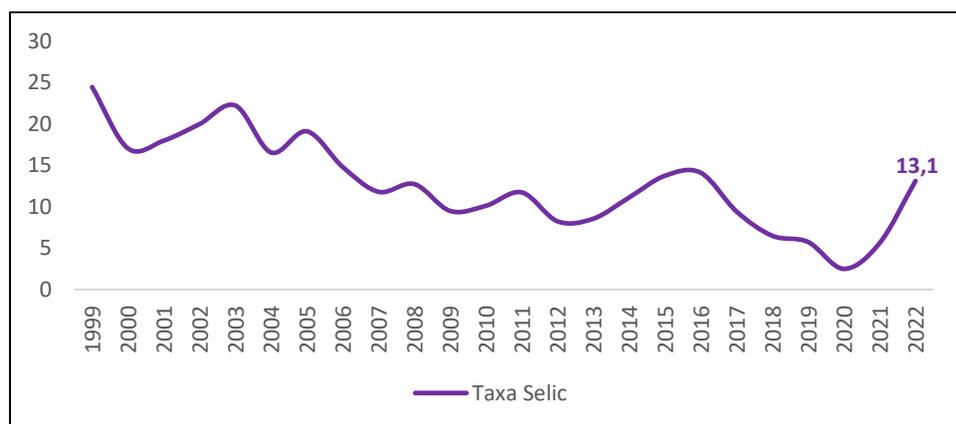
Cabe ao Comitê de Política Monetária (COPOM), órgão do Banco Central, definir as políticas para atingir a meta de inflação. A cada 45 dias, o comitê se reúne para analisar a conjuntura econômica e as expectativas dos agentes para a inflação nos próximos meses e anos e se há riscos da inflação se descolar da meta. A partir dos resultados da reunião o Copom define a taxa básica de juros, a taxa Selic, que se configura como o principal instrumento de política monetária (RIZZO, 2018, apud da Silva; Portugal, 2022). A evolução da inflação pode ser observada na Figura 6, assim como a Taxa Selic pode ser acompanhada na Figura 6.

Figura 6 - Evolução da meta de inflação e da inflação corrente



Fonte: Elaborado pelo autor (2023), dados do BCB.

Figura 7 - Evolução da Taxa Selic



Fonte: Elaborado pelo autor (2023), dados do BCB.

No primeiro ano do regime de Metas para a Inflação, o IPCA recuou de 8,94% para 5,97%, avançando para 12,5%, em 2002. Esse período foi marcado por turbulências macroeconômicas, com forte desvalorização da taxa de câmbio, motivadas pela mudança de governo de Fernando Henrique Cardoso para o governo

de Luiz Inácio Lula da Silva. Nesse período, a Taxa Selic média no ano recuou de 24,5%, em 1999, para 17,1% em 2002, elevando-se para 22,3%, em 2003.

A partir de 2004 até 2013 o IPCA oscilou entre 3% e 7,6%, dentro dos intervalos considerados pelo CMN. Por sua vez, a taxa Selic recuou de 16,5% para 7,3%. Esse período foi marcado pelo *boom das commodities* e evolução dos termos de troca do país, o que possibilitou o ingresso de capitais, o recuo da taxa de câmbio, a evolução da arrecadação e a geração de superávits primários do governo central. Essas variáveis contribuíram para o período de estabilidade macroeconômica e para recuo da taxa básica de juros.

Entre meados de 2013 e 2016, houve reversão dos fatores positivos registrados nos anos anteriores. A queda no preço das *commodities* e o conseqüente recuo dos termos de troca do país resultaram na desvalorização do câmbio. Adicionalmente, a queda na arrecadação do governo concomitantemente à elevação dos gastos públicos resultou na deterioração das contas públicas e na perda do Grau de Investimento, que acentuou a saída de capitais do país e a desvalorização da taxa de câmbio. Nesse período, o IPCA avançou de 5,9%, no quarto trimestre de 2013, para 10,7%, no quarto trimestre de 2015. Para tentar reduzir a inflação, a Banco Central elevou a taxa Selic de 9,0% para 14,3% no mesmo período.

O período entre o início de 2017 e 2019 foi marcado pelo recuo do IPCA de 10,7% para 4,3%. Vale destacar que esse período foi marcado pela aprovação da Emenda Constitucional 95, que tinha o objetivo de equilibrar as contas públicas, e pela mudança da TJLP para a TLP. Essas medidas contribuíram para a melhoria na percepção de estabilidade fiscal do país e, conseqüentemente, melhoria das expectativas em torno dos indicadores macroeconômicos.

Em 2020, o Brasil e o mundo foram atingidos pela pandemia de Covid-19. Para mitigar os efeitos econômicos das medidas tomadas para conter o surto da doença, os governos adotaram estímulos fiscais, como transferência de renda para as famílias. Os bancos centrais também adotaram medidas de estímulo monetário, como a redução das taxas de juros, para tentar estimular a economia. No Brasil, além dos estímulos econômicos do Governo Federal, o Bacen reduziu a taxa de juros para 2%, o menor patamar da série histórica.

Nos primeiros meses da pandemia, o recuo da atividade econômica resultou na queda do nível de preços. O IPCA no segundo trimestre de 2020 marcou 2%. Ao longo do segundo semestre do mesmo ano, a combinação entre as medidas de isolamento social e de estímulo econômico resultou no avanço expressivo do consumo de bens. Esse avanço, em conjunto com as medidas de restrição de atividade econômica, implicou na desarticulação das cadeias globais de valor e na elevação do preço de insumos e de bens finais. Esse cenário foi compatível com o rápido avanço da inflação no Brasil e no mundo. O IPCA avançou para 11,9% no segundo trimestre de 2022. Para tentar controlar o avanço de preços o Bacen iniciou um ciclo de alta de juros no início de 2021, elevando a Selic de 2% para 13,75%, no quarto trimestre de 2022. Esse período de juros em patamar elevado – ciclo de aperto monetário – ainda segue em curso no Brasil e na maior parte da economia mundial.

2.5 A hipótese de aumento na potência da política monetária brasileira: o problema e sua importância

A potência da política monetária brasileira tem sido objetivo de estudo por diversos autores. Minella et al. (2002) estudou a eficiência do Banco Central em controlar as expectativas de inflação por meio da estimação de uma função de reação do Banco Central que relacionasse a taxa de juros, as expectativas de inflação e o hiato do produto, nos moldes da Regra de Taylor. Os autores concluíram que o Bacen possui forte reação às expectativas inflacionárias. Adicionalmente, apontaram que o Regime de Metas para a Inflação tem se mostrado importante instrumento para o alcance de baixos níveis de inflação, mesmo em períodos de choques.

No mesmo sentido, Da Silva e Portugal (2002) analisaram a eficácia do regime de metas para a inflação por meio da estimação de uma Regra de Taylor e de exercícios de previsão via modelos de Vetores Autorregressivos (VAR). Os autores concluíram que os impactos iniciais da adoção do regime foram positivos, demonstrando sua importância como mecanismo de estabilidade de preços após a adoção do Plano Real.

Ao se avançar para os anos recentes, as transformações observadas no país, como a mudança da TJLP para a TLP e o aumento da participação do crédito livre na carteira de crédito total, trouxeram a temática sobre a evolução no potencial da política monetária do Banco Central.

A fim de avaliar a demanda agregada por meio de uma curva IS, que relaciona o nível de produto e a taxa de juros, e confirmar se a política monetária se tornou mais potente nos anos recentes, Jesus (2020) encontrou evidências de que a atividade econômica é negativamente afetada pelos juros reais e, adicionalmente, concluiu que os mecanismos de transmissão da política monetária têm operado melhor no país. A metodologia utilizada considerou a estimação de uma curva IS com diferentes medidas do *hiato do produto* – diferença entre o produto real e o potencial – e janelas móveis de tamanho fixo, a fim de obter parâmetros que variam no tempo Jesus (2020). Esses parâmetros seriam a sensibilidade aos juros do: consumo das famílias, do investimento, e do nível de utilização da capacidade instalada (NUCI). Os coeficientes foram estimados por Mínimos Quadrados Ordinários (MQO). Adicionalmente, o trabalho utilizou-se de uma estratégia de estimar regressões em janelas móveis de 50 períodos para cada medida de hiato do produto. Nesse sentido, as mudanças nos coeficientes de sensibilidade entre as janelas móveis seria um indicativo de alteração na potência da política monetária. Jesus (2020) considerou os períodos entre o terceiro trimestre de 2001 e o primeiro trimestre de 2020. O autor utilizou-se de dados trimestrais. Os resultados apontaram que os investimentos são mais sensíveis aos juros do que o consumo e ao NUCI, e que houve aumento nos coeficientes de sensibilidade entre os períodos, evidenciando o aumento no poder de influência das ações do Bacen sobre a economia.

O próprio Banco Central, por meio do Estudo Especial nº 77/2020 – Potência da política monetária – realizou dois exercícios para avaliar evidências de que as mudanças recentes no mercado de crédito e de capitais tenderiam a aumentar a potência da política monetária. No primeiro exercício, analisou-se a sensibilidade das taxas de juros de operações de crédito a movimentos na taxa Selic. As operações de crédito foram segmentadas pela origem dos recursos, se livres ou direcionados, e por tipo de tomador, pessoa físicas (PF) ou pessoa jurídica (PJ). Foram utilizados dados mensais a partir de março de 2021. Em seguida, para cada grupo de operação de crédito, estimou-se um vetor de correção de erros (VEC), relacionando a taxa de juros r , desse grupo à taxa básica de juros *SELIC*. Os resultados apontam que as taxas de juros incidentes nas operações de crédito com recursos livres são mais sensíveis às variações na taxa básica de juros que as taxas aplicadas nas operações com recursos direcionados. Por sua vez, no segundo exercício, o estudo estimou um modelo

econométrico com períodos amostrais diferentes, semelhante ao trabalho de Jesus (2020). O objetivo era apontar que, caso houvesse ocorrido mudanças na transmissão da política monetária, se encontraria comportamento distinto entre o modelo estimado com um período mais longo e outro modelo estimado com período mais recente. O exercício utilizou um modelo Semiestrutural de quatro equações:

- I. Regra de Taylor;
- II. Curva IS;
- III. Curva de Phillips;
- IV. Uma equação de paridade descoberta de taxa de juros que associava variações da taxa de câmbio a variações das taxas de juros básicas.

O modelo foi associado a um arcabouço de espaço de estados e estimado por métodos bayesianos, considerando o primeiro período, 2003 a 2019, e o segundo período, 2003 a 2014. O estudo apontou que o hiato do produto apresentou maior sensibilidade aos juros na estimação com o primeiro período, que contém dados mais recentes. Essa maior sensibilidade do hiato do produto às variações no juro básico seria reflexo do aumento no potencial das ações do Bacen sobre a atividade econômica e, portanto, sobre o controle da inflação.

Já Daniel (2015) buscou avaliar se as políticas de crédito direcionado do BNDES, entre elas as operações com a TJLP, reduziram a potência da política monetária. O autor estimou uma curva IS em dois períodos, adicionando termo específico ao crédito direcionado do BNDES, a fim de estimar o impacto do crédito no consumo. A metodologia utilizada por Daniel (2015) para a estimação foi o Método dos Momentos Generalizados (GMM). No primeiro período, a participação do crédito direcionado do Banco no crédito total é menor que no segundo período. No entanto, os resultados encontrados por Daniel (2015) divergem dos demais trabalhos citados, ao apontar que não houve alteração na potência da política monetária entre o período em que o crédito direcionado teve maior participação no crédito total.

Rizzo (2018) também avaliou o impacto do crédito direcionado na potência da política monetária brasileira. O trabalho estimou uma Regra de Taylor – função de reação do Bacen – modificada, que levava em consideração uma variável de crédito direcionado. O método utilizado pelo trabalho foi o de Mínimos Quadrados Ordinários (MQO) com correção dos erros-padrão. A autora concluiu que a participação do

crédito direcionado exerceu influência positiva na decisão do Banco Central sobre o nível da taxa Selic, levando a instituição a promover altas do juro básico mais intensas devido ao tamanho do crédito direcionado sobre o crédito total.

Considerando os trabalhos recentes sobre o aumento no potencial da política monetária brasileira e o avanço do crédito como proporção do PIB ao longo dos anos, a importância deste estudo está em verificar o comportamento das curvas de crédito e de juros e elaborar a previsão de ambos para os próximos trimestres. Este processo de previsão para as concessões de créditos se mostra relevante para os formuladores de políticas públicas na conjuntura atual de aumento de taxas de juros mundiais.

4 OBJETIVOS

4.1 Objetivo geral

O presente estudo pretende elaborar as previsões do saldo de crédito nos quatro trimestres de 2022, como período de validação, por meio do método de Box-Jenkins.

4.2 Objetivos específicos

Estimar dois modelos de previsão para o saldo de crédito nos próximos trimestres e avaliar a relação entre o crédito e a Taxa Selic por meio de uma regressão dinâmica.

5 METODOLOGIA

Esta seção concentrar-se-á na exposição da base de dados, de suas variáveis e a justificativa da sua escolha. Quanto à variável dependente, há uma breve explanação de como ela é construída e os indicadores que a compõem.

Em seguida, é apresentada a equação a ser estimada juntamente com a justificativa do modelo escolhido para o este trabalho.

5.1 Base de Dados e Descrição das variáveis

A base de dados consiste no saldo das operações de crédito, obtidas por meio do Sistema Gerenciador de Séries Temporais (Banco Central) para o período de 2000 a 2022. Essa variável reflete o estoque de crédito ampliado ao setor não financeiro concedidos pelas instituições do Sistema Financeiro Nacional (SFN). O enfoque dado ao saldo de crédito está relacionado à sua característica de ser um dos principais canais de transmissão da política monetária. Nesse sentido, espera-se que aumentos nas taxas de juros sejam seguidos por períodos de contração no estoque de crédito,

bem como redução de taxas de juros sejam acompanhadas por avanço no estoque de crédito. Como variável controle, foi utilizado a Taxa Selic acumulada no mês anualizado (base considerando média para 252 dias úteis), do Banco Central. As variáveis estão relacionadas na Tabela 1.

Tabela 1 - Variáveis Utilizadas

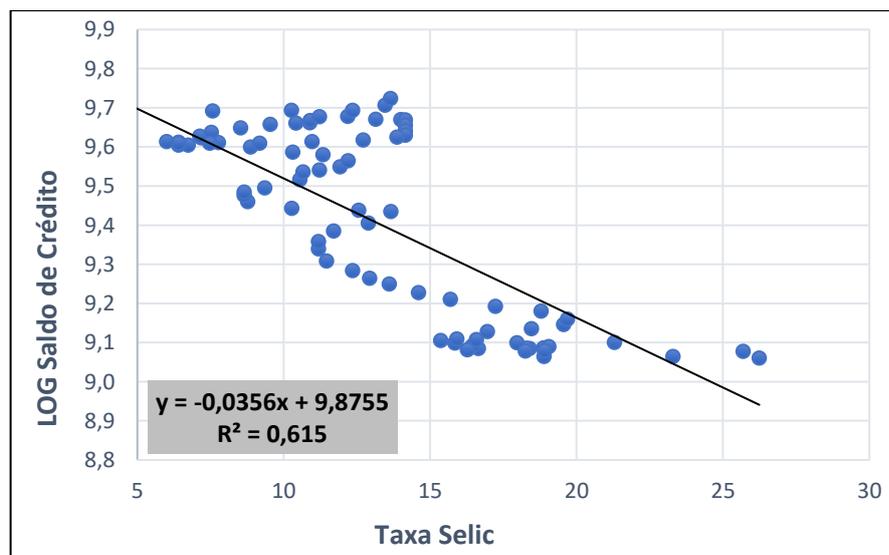
Variável	Período	Fonte de dados
Estoque de crédito (em R\$)	1º trimestre 2000 ao 4º trimestre 2022	Banco Central
Taxa de Juros (Selic)		

Fonte: Elaborado pelo autor (2023).

Na Figura 8 é possível observar o diagrama de dispersão entre a Taxa Selic e o logaritmo do saldo de crédito do SFN no período mencionado. Optou-se pela transformação logarítmica da série considerando a estabilização da variância e a redução da amplitude nas variações da série, tornando-a mais estável.

De acordo com o coeficiente de determinação (R^2), os dados da Taxa Selic explicaram 61,5% da variabilidade do saldo de crédito, apontando para uma relação significativa entre as séries.

Figura 8 - Diagrama de Dispersão



Fonte: Elaborado pelo autor (2023), dados do BCB.

5.2 Metodologia

5.2.1 Séries temporais – aspectos gerais

Séries temporais podem ser definidas como um conjunto de variáveis aleatórias distribuídas no tempo. Quando Y denota uma variável aleatória, ela pode ser contínua $Y(t)$, nos quais valores fracionados na reta real fazem sentido, ou discretas Y_t , se assume apenas valores inteiro (Gujarati e Porter, 2011). Ao analisar séries temporais, é comum ter diversos objetivos, como compreender o mecanismo gerador da série, realizar previsões futuras, descrever seu comportamento ao longo do tempo e identificar possíveis padrões periódicos nos dados. Para tanto, são utilizados modelos estocásticos, isto é, processos controlados por leis probabilísticas. De acordo com Morettin e Tolo (1987), estes modelos devem ser simples e parcimoniosos, com o menor número de parâmetros possível.

A realização de estimações em séries temporais requer a suposição de estacionariedade da série. Em geral, série econômicas são compostas pela tendência, pelo componente estacionário e pelo ruído (Bueno, 2008).

Em linhas gerais, um processo estocástico será chamado estacionário se sua média e variância forem constantes ao longo do tempo e o valor da covariância entre os dois períodos de tempo depender apenas da distância, do intervalo, ou da defasagem entre os dois períodos e não o tempo real ao qual a covariância é computada.

Nesse sentido, uma série é fracamente estacionária se a média, variância e covariância forem constantes.

$$E(Y_t) = \mu$$

$$var(Y_t) = E(Y_t - \mu)^2 = \sigma^2$$

$$Cov(Y_t, Y_{t-j}) = E(Y_t, Y_{t-j}) - E(Y_t)E(Y_{t-j}) = \gamma_k$$

Séries que não apresentam alguma dessas propriedades são consideradas não estacionárias e necessitam de uma transformação. Em geral, a transformação mais comum consiste em tirar diferenças sucessivas até se obter a estacionariedade da

série. A constatação ou não de estacionariedade da série se dá por meio de testes de raiz unitária¹.

Existem vários modelos para séries temporais. De acordo com Morettin e Tolo (1987) podemos classificá-los como grupo de modelos *não-paramétricos* (número infinito de parâmetros) e *paramétricos* (número finito de parâmetros). Nesse último, os modelos mais comuns são os de regressão, os modelos autorregressivos e de médias móveis (ARMA), os modelos autorregressivos integrados de médias móveis (ARIMA), modelos de memória longa (ARFIMA), modelos estruturais e modelos não-lineares.

Para Morettin e Tolo (1987), a classe dos Modelos ARIMA são capazes de descrever o comportamento de séries estacionárias e:

- a) Descrever o comportamento de séries econômicas onde os erros são autocorrelacionados e influenciam a evolução do processo;
- b) descrever séries não estacionárias do tipo homogêneas, isto é, que não apresentem comportamento explosivo.

Séries podem tornar-se estacionárias com um número finito de diferenças, geralmente uma ou duas.

A primeira diferença de Y_t é definida por:

$$\Delta Y_t = Y_t - Y_{t-1},$$

A segunda diferença dada por:

$$\Delta^2 Y_t = \Delta[\Delta Y_t] = \Delta [Y_t - Y_{t-1}],$$

Ou seja,

$$\Delta^2 Y_t = Y_t - 2Y_{t-1} + Y_{t-2},$$

De modo geral, a n-ésima diferença de Y_t ($n \geq 1$) é definida como:

$$\Delta^n Y_t = \Delta [\Delta^{n-1} Y_t].$$

¹ Raiz unitária define a situação de não estacionariedade. De acordo com Gujarati e Porter (2011), para um modelo de um passeio aleatório $Y_t = \rho Y_{t-1} + u_t$ para $-1 \leq \rho \leq 1$; se $\rho = 1$ teremos a situação de não estacionariedade em que, utilizando um operador de defasagens L ; $(1-L)Y_t = u_t$, obteríamos $L=1$, daí o nome de raiz unitária.

Antes de passar a sequência do trabalho, é preciso considerar um conceito importante em processos estocásticos, análises e previsões de séries temporais; o ruído branco, ou um processo puramente aleatório. É considerado um ruído branco o termo de erro que tem média zero, variância constante e é não correlacionado. Adicionalmente, se o termo de erro apresentar distribuição normal, o processo pode ser chamado de ruído branco gaussiano (Gujarati e Porter, 2011).

$$\begin{aligned} E(\varepsilon_t) &= 0, \\ E(\varepsilon_t^2) &= \sigma^2 \\ E(\varepsilon_t \varepsilon_{t-j}) &= 0 \end{aligned}$$

Nesse sentido, pode-se dizer que um processo do tipo ruído branco é um processo estocástico estacionário.

5.2.2 Modelos ARMA

Ao se analisar e verificar a estacionariedade da série, o passo seguinte é definir o modelo que se ajusta ao conjunto dos dados. Em geral, os modelos estudados neste trabalho são casos particulares de um *modelo de filtro linear*. De acordo com Morettin e Tolo (1987), esses modelos pressupõem que a série temporal seja gerada por meio de um filtro, cuja entrada é um ruído branco.

5.2.2.1 Processo Autorregressivos (AR)

O processo autorregressivo de ordem 1 – AR (1) é identificado com a seguinte estrutura:

$$\begin{aligned} Y_t &= c + \phi Y_{t-1} + \varepsilon_t, \\ \varepsilon_t &\sim i.i.d.^2, \text{ um ruído branco} \end{aligned}$$

O valor previsto de Y no período t é uma proporção (ϕ) – limitado entre -1 e 1 – do seu valor no período anterior ($t-1$), acrescido de um choque aleatório, ou perturbação no período – t (ε). Os valores de Y são expressos como desvios com base em um valor médio. Caso o processo também dependa da sua variável defasada em dois períodos (Y_{t-2}), o processo é conhecido como Autorregressivo de Ordem 2, AR (2).

De acordo com Toscano (2022), um modelo autorregressivo de ordem p – AR(p) – é definido da seguinte forma:

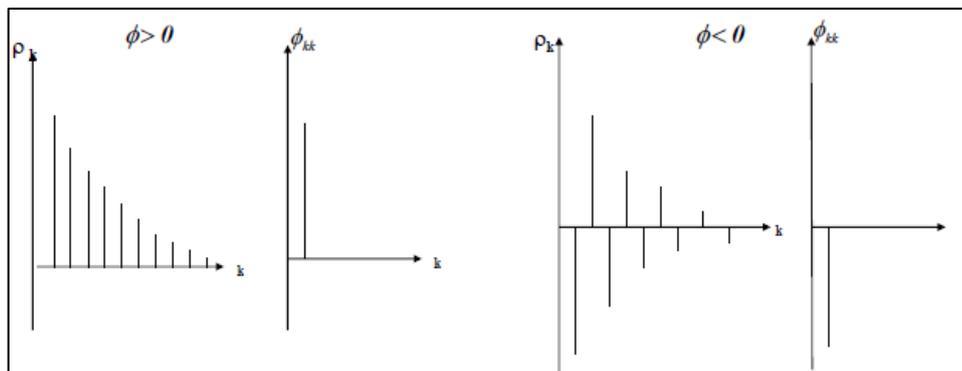
$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t,$$

Usando um operador de defasagens B^2 :

$$(1 - \phi_1 B - \phi_2 B^2 - \phi_3 B^3 - \dots - \phi_p B^p) Y_t = c + \varepsilon_t$$

O processo AR e sua ordem serão identificados pela análise da sua Função de Autocorelação (FAC) e Função de Autocorelação Parcial (FACP). No processo AR(1) a FAC apresenta decaimento exponencial para zero, enquanto que na FACP a primeira correlação é significativa e as demais apresentam rápido decaimento. Esse processo pode ocorrer de forma alternada, conforme apontado na Figura 9.

Figura 9 – Exemplo correlogramas FAC e FACP modelo AR (1)



Fonte: Toscano, 2022.

Para que um modelo AR seja estacionário, existem algumas restrições para os parâmetros.

Para $p = 1, -1 < \phi < 1,$

$p = 2, \phi_1 + \phi_2 < 1, \phi_2 - \phi_1 < 1$ e $-1 < \phi_2 < 1$

Para $p > 2$ as condições são mais complicadas, sendo necessário uma análise mais aprofundada (Bueno, 2008)

5.2.2.2 Processo Média Móvel (MA)

O processo de média móvel de ordem 1 – MA (1) é identificado com a seguinte estrutura:

$$Y_t = \mu + \varepsilon_t + \theta \varepsilon_{t-1},$$

² O operador $B[\cdot]$ simplifica a equação estimada ao representar as defasagens de uma série temporal. Seja Z_t uma variável definida no tempo t , um operador de defasagens seria: $B^m Z_t = Z_{t-m}$, Mattos (2022)

$\varepsilon_t \sim i.i.d.^2$, um ruído branco

Nesse processo, Y_t depende do erro presente (ε_t) e uma proporção do erro imediatamente anterior ($\theta\varepsilon_{t-1}$). Caso o processo também dependesse do erro em dois períodos anteriores – ($\theta\varepsilon_{t-2}$), seria um MA (2) e assim por diante (Bueno, 2008).

A generalização do processo de médias móveis de ordem q – MA(q) – pode ser descrito da seguinte forma:

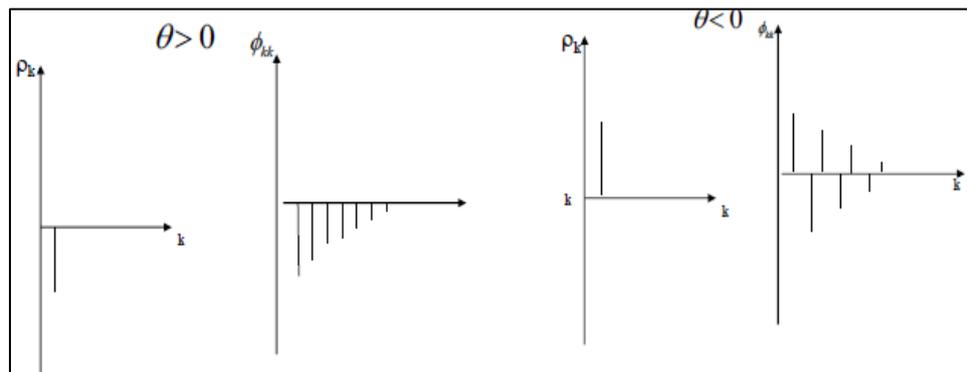
$$Y_t = \mu + \varepsilon_t - \theta_1\varepsilon_{t-1} - \theta_2\varepsilon_{t-2} - \dots - \theta_q\varepsilon_{t-q},$$

Utilizando o operador de defasagens B[.], pode-se escrever:

$$Y_t = (1 - \theta_1B - \theta_2B^2 - \dots - \theta_qB^q)\varepsilon_t$$

A identificação de um processo MA também é realizada pela análise da FAC e FACP. No processo MA (1) a FAC possui a primeira defasagem significativa, enquanto a FACP apresenta decaimento exponencial nas autocorrelações parciais. Esse decaimento exponencial também pode ocorrer de forma alternada, conforme apontado na Figura 10.

Figura 10 - Exemplo correlogramas FAC e FACP modelo MA (1)



Fonte: Toscano, 2022.

Assim como o modelo AR, o processo MA também exige algumas restrições nos parâmetros. De acordo com Toscano (2022), essas condições definem a invertibilidade necessária ao processo de médias móveis. Essa condição de invertibilidade significa a capacidade de escrever um MA (q) como um AR (∞).

Para $q = 1$, $-1 < \theta < 1$.

Para $q = 2$, $\theta_1 + \theta_2 < 1$, $\theta_2 - \theta_1 < 1$ e $-1 < \theta_2 < -1$,

Para $q > 2$ as condições para coeficientes são mais complicadas, também sendo necessário uma análise mais aprofundada (Bueno, 2008).

Ainda de acordo com Bueno (2008), a invertibilidade é necessária para três propósitos.

- Sem invertibilidade a série não poderia ser estimada recursivamente, usando observações passadas;
- Para haver unicidade de resultados;
- Para gerar funções de autocorrelação parciais

Vale destacar que um processo de médias móveis é sempre estacionário, ao passo que processos autorregressivos são sempre invertíveis.

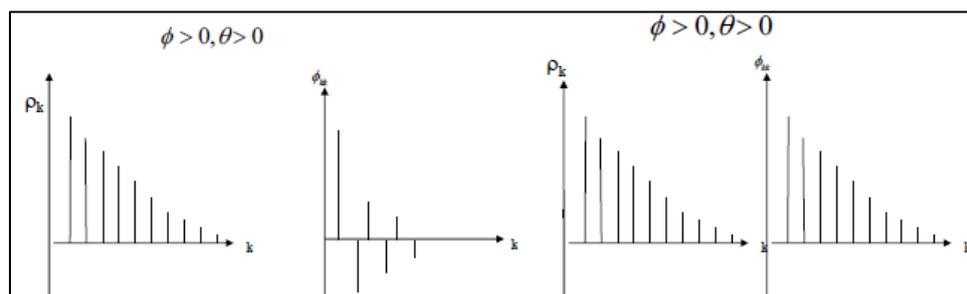
5.2.2.3 Modelos Autorregressivos e de Médias Móveis - ARMA

O processo ARMA é aquele que combina o processo autorregressivos e de médias móveis. O processo ARMA (1,1) pode ser definido como:

$$Y_t = c + \phi Y_{t-1} + \varepsilon_t - \theta \varepsilon_{t-1}$$

O processo é estacionário se $-1 < \phi < 1$ e invertível se $-1 < \theta < 1$. O processo é caracterizado por decaimento exponencial na FAC e na FACP, com autocorrelações significativas nos dois, conforme apontado na Figura 11.

Figura 11 - Exemplos de correlogramas FAC e FACP - ARMA (1,1)



Fonte: Toscano, 2022.

A generalização do processo de autorregressivos de médias móveis é o ARMA(p,q). Ele pode ser descrito da seguinte forma:

$$Y_t = c + \phi Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

Utilizando o operador B[.], pode-se reescrever um processo ARMA (p,q).

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Y_t = c + (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \varepsilon_t$$

Para que um processo ARMA (p, q) seja invertível e estacionário a parte AR precisa ser estacionária e a parte MA invertível.

Quando um processo não estacionário que exige diferenciação até que se torne estacionário, a notação dos processos ARMA será (p, d, q) , sendo d a ordem de integração, ou diferenciação aplicadas na série original. Esses processos são conhecidos como “processos lineares não-estacionários homogêneos”. Após a aplicação das diferenças, o processo torna-se autorregressivo integrado de médias móveis – ARIMA(p, d, q). Esse processo pode ser descrito da seguinte forma:

$$\Delta Y_t = c + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

Sendo que $\Delta Y_t = Y_t - Y_{t-1}$

De acordo com Epifânio (2015), além da tendência, as séries podem apresentar componentes sazonais, que repetem o comportamento em determinados períodos, por exemplo, o aumento do desemprego no primeiro trimestre do ano em função das demissões de trabalhadores temporários no final do ano anterior. Se plotarmos essa série, poderemos observar “picos” nesses períodos. ($s=4$). O modelo pode então ser generalizado para um modelo SARIMA $(p, d, q)(P, D, Q)_s$. As três últimas ordens referem-se a parte sazonal da série, mais especificamente, um processo autorregressivo sazonal (P), a diferenças sazonais (D) e a um processo de média móvel sazonal (Q). O processo SARIMA $(p, d, q)(P, D, Q)_s$ pode ser escrito da seguinte maneira.

$$\Delta Y_t = c + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \Phi_1 Y_{t-12} + \dots + \Phi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} - \Theta_1 \varepsilon_{t-12} - \dots - \Theta_q \varepsilon_{t-q}$$

Em processo sazonais, a diferenciação também deve ser realizada na parte sazonal, encontrando valores para d e D .

Conforme o autor, as ordens dos processos também serão definidas na FAC e FACP. Desse modo, será necessário verificar autocorrelações significativas em ambos, estimando os valores de p e q por meio da análise do comportamento das autocorrelações nos “lags” (defasagens) 1,2,3.... e estimando os valores de P e Q por meio do comportamento da FAC nos “lags” sazonais. Por exemplo, na série da taxa

de desemprego, citada acima, as autocorrelações referentes a parte sazonal serão estatisticamente diferentes de zero nos “lags” múltiplos de 4.

5.2.2.4 Função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACP)

A FAC e a FACP possibilitam identificar o tipo de processo que descreve uma série temporal.

A autocorrelação entre Y_t e Y_{t+j} – FAC – pode ser definida como:

$$p_k = \frac{E[(Y_t - \mu)(Y_{t-j} - \mu)]}{\sqrt{E[(Y_t - \mu)^2]E[(Y_{t-j} - \mu)^2]}}$$

Considerando a condição de estacionariedade, tem-se que: $E[(Y_t - \mu)^2] = E[(Y_{t-j} - \mu)^2]$. Nesse sentido, $\sqrt{E[(Y_t - \mu)^2]E[(Y_{t-j} - \mu)^2]} = \sigma^2 = \gamma_0$, e a autocorrelação de ordem j pode ser expressa por:

$$p_k = \frac{\gamma_k}{\gamma_0}$$

Assim, pode-se apresentar todas as autocorrelações p_k para $k= 1, 2, \dots$ em um gráfico chamado correlogramas. De acordo com Bueno (2008), “A função de autocorrelação é o gráfico da autocorrelação contra a defasagem e permitirá identificar a ordem q de um processo MA”. A FAC possui as seguintes propriedades:

$$p_0 = 1$$

$$|p_j| \leq 1 \text{ para todo } j$$

$$p_{-j} = p_j \text{ para todo } j$$

Por sua vez, a Função de Autocorrelação Parcial (FACP) mantém apenas correlação pura entre as observações, eliminando as correlações implícitas (Bueno, 2008). Para Gujarati e Porter (2011), “a autocorrelação parcial é a correlação entre Y_t e Y_{t-k} depois de remover o efeito dos Y intermediários. A FACP pode ser definida como segue:

$$Y_t = \phi_{j,1}Y_{t-1} + \phi_{j,2}Y_{t-2} + \dots + \phi_{j,j}Y_{t-j} + \varepsilon_t \quad j = 1, 2, \dots$$

$$\phi_{jj} = \text{Corr}(Y_t, Y_{t-j}/Y_{t+1}, \dots, Y_{t+j-1})$$

5.2.3 A metodologia Box-Jenkins

A metodologia foi introduzida em 1976 por George Box e Gwilym Jenkins, no livro *Time Series Analysis: Forecasting and control*. Para Rocha (2002), a principal concepção dos modelos Box-Jenkins é que um processo estocástico pode ser explicado pelos valores passados da série e pelo termo de erro.

Por meio da metodologia Box-Jenkins é possível identificar se o modelo segue um processo autorregressivo (AR) e, se sim, em qual ordem de p ; se o modelo segue um processo de médias móveis (MA), e qual o valor de q ; se segue um processo Autorregressivo de Médias Móveis (ARMA) ou mesmo um processo Autorregressivo Integrado de Médias Móveis (ARIMA) e qual a ordem de p , d e q .

A metodologia consiste em quatro etapas:

1. **Identificação:** através do auxílio dos correlogramas de função de autocorrelação (FAC) e função de autocorrelação parcial (FACP), pode-se identificar os valores apropriados de p , d e q .
 - (a) Modelo AR(p)
 - (b) Modelo MA(q)
 - (c) Modelo ARMA(p, q)
2. **Estimação:** após identificar as ordens do modelo, o passo seguinte é a estimação dos parâmetros. Ela pode ser realizada pelo Método dos Momentos, Mínimos Quadrados Ordinários, Máxima Verossimilhança Condicional e Máxima Verossimilhança Não Condicional.
3. **Verificação:** após escolher o modelo específico e estimado seus parâmetros, verifica-se se o modelo se ajusta bem à variabilidade da série. De acordo com Gujarati e Porter (2011), a metodologia Box-Jenkins é um processo iterativo.
4. **Previsão:** a última etapa é a previsão.

5.2.3.1 Verificação de modelos ARMA(p, q)

A verificação do modelo consiste em avaliar os seguintes passos:

- a) Os parâmetros ϕ_s estão dentro da região de estacionariedade?
- b) Os parâmetros θ_s estão dentro da condição de invertibilidade?

- c) Os parâmetros são significativamente diferentes de zero?
- d) O resíduo é ruído branco?

Para determinar o comportamento estacionário da série, pode-se realizar o teste de raiz unitária de Dickey-Fuller Aumentado (ADF), no qual são obtém a estatística de Dickey – Fuller. Esse valor é comparado ao valor tabelado de Dickey – Fuller. No teste, considera-se:

$H_0: \alpha = 0$ (há raiz unitária, portanto, a série é não estacionária)

$H_1: \alpha < 0$ (a série é estacionária)

Por sua vez, o componente de médias móveis (MA) de uma série é sempre estacionário por definição, como já mencionado.

É preciso testar também se os parâmetros do modelo são significativamente diferentes de zero:

$H_0: \phi_s = 0$ vs $H_1: \phi_s \neq 0$

$H_0: \theta_s = 0$ vs $H_1: \theta_s \neq 0$

Por fim, é necessário verificar se os resíduos do modelo são do tipo ruído branco, como mencionado. Para tanto:

1. os resíduos devem estar localizados ao redor da reta centrada e não exibem a presença de nenhuma configuração especial;
2. os resíduos padronizados estão dentro da faixa entre -2 e 2, não sendo observados elementos discrepantes;
3. No gráfico de FAC e FAP dos resíduos, é possível validar a suposição de que os erros são não autocorrelacionados;
4. É necessário verificar ainda se os resíduos seguem uma distribuição normal, o que pode ser feito por meio do teste de Anderson Darling em que:

$H_0: os\ erros\ seguem\ uma\ distribuição\ normal\ vs$

$H_1: os\ erros\ não\ seguem\ uma\ distribuição\ normal$

5.2.3.2 Escolha dos modelos

Existem muitos critérios de informação para a seleção do melhor modelo estimado, entre eles, os mais utilizados são:

1. Critério de AIC: introduzido em 1971 por Akaike, esse critério é definido por:

$AIC(k) = n \ln \sigma_a^2 + 2K$, sendo k o número de parâmetros estimados e σ_a^2 a variância dos resíduos (Toscano, 2022). Por esse critério, o melhor modelo é aquele que apresenta o menor valor de AIC.

2. Critério de BIC: o Critério Bayesiano de Schwarz é dado por:

$BIC(p,q) = LN(\sigma^2) + (p + q) \left[\frac{Ln(n)}{n} \right]$. Por esse critério, o melhor modelo também é aquele que minimiza o valor de BIC.

5.2.3.3 Previsão

A previsão é a etapa final da metodologia de Box-Jenkins e consiste em realizar a projeção de até h passos à frente para os modelos selecionados nas etapas anteriores (ARRAIS, 2019).

Para a escolha do melhor modelo de previsão, entre os modelos selecionados deve-se considerar algumas estatísticas baseadas nos erros de previsão. Isso por que, de acordo com Campos, Clemente e Cordeiro (2006), modelos que apresentem as evidências estatísticas que o tornem consistentes, como AIC e BIC, podem não gerar resultados de previsão satisfatórios.

A fim de testar a acurácia entre os modelos propostos, são considerados alguns índices de desempenho no período amostral e no período de validação. De acordo com Toscano (2022), são considerados como estatística básica:

1. Erro Percentual Absoluto Médio ou Desvio Absoluto Médio:

$$MAPE = \left(\frac{1}{h} \sum_{j=1}^{T+h} \frac{e_j}{y_j} \right) 100\%$$

2. Erro Quadrado Médio ou Desvio Quadrado Médio:

$$MSE = \frac{1}{h} \sum_{j=T+1}^{t+h} e_j^2$$

3. Erro Absoluto Médio ou desvio absoluto médio

$$MAD = \frac{1}{h} \sum_{j=T+1}^{T+h} |e_j^2|$$

4. Raiz do Erro Quadrado Médio:

$$RMSE = \sqrt{\frac{1}{h} \sum_{j=T+1}^{t+h} e_j^2}$$

5. Coeficiente de Desigualdade de Theil (Theil Inequality Coefficient):

$$TIC = \frac{\sqrt{\frac{1}{T-h} \sum_{j=1}^{T-h} e_j^2}}{\sqrt{\frac{1}{T-h} \sum_{j=1}^{T-h} \hat{y}_j^2} + \sqrt{\frac{1}{T-h} \sum_{j=1}^{T-h} y_j^2}}$$

O TIC está limitado entre [0,1]. Quando o valor do coeficiente for zero, significa ajustamento perfeito do período amostral.

A escolha do melhor modelo deve levar em consideração aquele que apresente o menor valor em algumas das estatísticas dos erros de previsão.

5.2.4 Regressão Dinâmica

Os modelos de regressão dinâmica são modelos de regressão múltipla nos quais são considerados, não só as variáveis em seus valores correntes, como nos seus valores defasados. Nesse sentido, o modelo descreve as relações entre as variáveis ao longo do tempo. O modelo de equação dinâmica pode ser descrito como:

$$Y_t = \beta_0 + \beta_1 X_1 + \beta_1 X_{t-1} + \dots + \beta_k X_{t-k} + \varphi_1 Y_{t-1} + \dots + \varepsilon_t$$

Onde:

$$Y_t = \text{Variável dependente}$$

$$\beta_t = \text{Coeficientes}$$

$$X_t = \text{Variáveis exógenas}$$

$$\varepsilon_t = \text{resíduos do modelo}$$

De acordo com Almeida, citado por Epifânio (2015), os parâmetros do modelo são estimados pelo Método dos Mínimos Quadrados Ordinários (MQO). Porém, o processo deve ser realizado de maneira *bottom-up*, ou seja, a partir de um modelo simples, vai se acrescentando novas defasagens e/ou variáveis exógenas até se encontrar um modelo adequado. Se identificado a presença de autocorrelação significativa nos resíduos acrescenta-se mais “lags” da variável dependente ou explicativa.

Adicionalmente, o autor acrescenta que deve ser analisado a presença de multicolinearidade, ou seja, os regressores da variável dependente são correlacionados. Para Gujarati e Porter (2011), caso seja identificada alta multicolinearidade no modelo, as principais consequências podem ser:

- 1) Embora sejam os melhores estimadores lineares não viesados, os estimadores de MQO têm grandes variâncias e covariâncias, tornando difícil uma estimação precisa.
- 2) Devido à consequência 1, os intervalos de confiança tendem a ser muito mais amplos, levando à aceitação imediata da “hipótese nula igual a zero” (isto é, o verdadeiro coeficiente populacional igual a zero).
- 3) Também, devido à consequência 1, a razão t de um ou mais coeficientes tende a ser estatisticamente insignificante.
- 4) Embora a razão t de um ou mais coeficientes seja estatisticamente insignificante, R^2 , a medida geral de qualidade do ajustamento, pode ser muito alto.
- 5) Os estimadores de MQO e seus erros padrão podem ser sensíveis a pequenas alterações nos dados. (GUJARATI E PORTER, 2011, 336).

A presença de multicolinearidade de um modelo pode ser verificada por meio do Fator de Inflação da Variância (FIV). Ele é um indicador que observa a velocidade com a qual as variâncias e covariâncias aumentam. O FIV pode ser definido como:

$$FIV = \frac{1}{(1 - R_j^2)} \quad j = 1, 2 \dots k$$

Em que R_j^2 = coeficiente de correlação múltipla resultante da regressão de X_j nos $k-1$ preditores.

Nesse sentido, de acordo com GUJARATI E PORTER (2011), o FIV mostra “como a variância de um estimador aumenta pela presença de multicolinearidade”.

A análise do FIV segue os critérios apresentados na Tabela 2.

Tabela 2 - Análise do resultado da inflação da variância – FIV

VIF	Resultado
VIF = 1	Não correlacionadas
$1 < VIF < 5$	Correlação Moderada
$VIF > 5$ a 10	Alta correlação

Fonte: Reis, citado por Epifânio (2015).

Se identificado alta multicolinearidade, deve-se retomar a característica *bottom-up* do modelo removendo preditores menos importantes ou altamente correlacionados entre si (Epifânio, 2015).

5.2.5 Análise dos Resíduos

Após a estimação dos modelos, é necessário verificar os resíduos. Deve-se confirmar as suposições de que os erros são do tipo ruído branco, com média zero $E[\varepsilon_t] = 0$ e variância constante $Var(\varepsilon_t) = \sigma_\varepsilon^2$, conforme já mencionado.

Para confirmar essas hipóteses, deve-se observar na análise gráfica se os resíduos estão dispersos ao redor de uma reta centrada em zero e entre a faixa $[-2,2]$ Toscano (2021).

Após essa primeira verificação, analisa-se os correlogramas FAC e FACP dos resíduos para identificar se as correlações são estatisticamente diferentes de zero – as observações deverão estar abaixo da faixa de significância. Vale destacar que confirmada essa hipótese, há indícios de que os erros sejam do tipo ruído branco. Para Bueno (2008), se houver correlações significativas dos resíduos deve-se descartar o modelo estimado, pois a previsão pode não ser assertiva.

A hipótese de autocorrelação dos resíduos também pode ser confirmada pela aplicação de dois testes; o de Ljung-Box e o de Durbin-Watson, descritos a seguir.

Teste de Ljung-Box

Para verificar a hipótese de não autocorrelação, ou seja, se as k primeiras autocorrelações são nulas, como segue:

$$H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0$$

Pode-se utilizar a estatística Q de Box e Pierce: $Q = \frac{T(T+2) \sum_{t=1}^T (r_t^2)}{(T-1)} \sim \chi^2_{(k-m)}$, sendo m o número de parâmetros livres do modelo. Se Q for grande quando comparado a um percentil apropriado, rejeita-se H_0 .

Em 1978, Ljung-Box propuseram uma variação do teste, a saber:

$Q(k) = n(n+2) \sum_{j=1}^K \frac{r_j^2}{(n-j)}$ que terá uma distribuição de χ^2 com $K-p-q$ graus de liberdade. A hipótese de ruído branco seria rejeitada para valores grandes de $Q(K)$.

Ainda de acordo Morettin e Toloi (1987), basta utilizar as 10 ou 15 primeiras defasagens.

Teste de *Durbin-Watson*

A verificação de autocorrelação dos resíduos também pode ser feita por meio do teste de Durbin-Watson. De acordo com GUJARATI E PORTER (2011), a estatística é utilizada para verificar a existência de correlação de primeira ordem nos termos de erro. A estatística pode ser definida como:

$$d = \frac{\sum_{t=2}^{t=n} (\hat{u}_t - \hat{u}_{t-1})^2}{\sum_{t=1}^{t=n} \hat{u}_t^2}$$

Sendo \hat{u}_t os resíduos estimados em determinado período e n o número de observações da série. A nula é a de que há ausência de autocorrelação, enquanto a hipótese alternativa é a da existência de correlação de primeira ordem nos termos de erro.

Teste de Normalidade de *Anderson-Darling*

Após verificar a autocorrelação dos resíduos, deve-se verificar se eles possuem distribuição normal. Essa análise pode ser feita por meio do gráfico de probabilidade normal, que consiste na dispersão dos resíduos contra os valores ajustados (y) da série. Se o gráfico de probabilidade normal se mostrar como uma linha reta, aproximadamente, pode-se inferir que os resíduos seguem uma distribuição normal GUJARATI E PORTER (2011).

Para além do gráfico de probabilidade normal, há o teste de Anderson-Darling. Nesse teste, a hipótese nula é a de que os erros seguem uma distribuição normal. Se o valor p da estatística AD calculada for alto, não se rejeita a hipótese nula.

Vale destacar que, se os erros forem do tipo ruído branco, com média zero $E[\varepsilon_t] = 0$ e variância constante $Var(\varepsilon_t) = \sigma_\varepsilon^2$, e seguirem uma distribuição normal, esse processo é chamado de *ruído branco gaussiano* Toscano (2021).

6 ANÁLISE DE RESULTADOS

6.1 Análise da Série

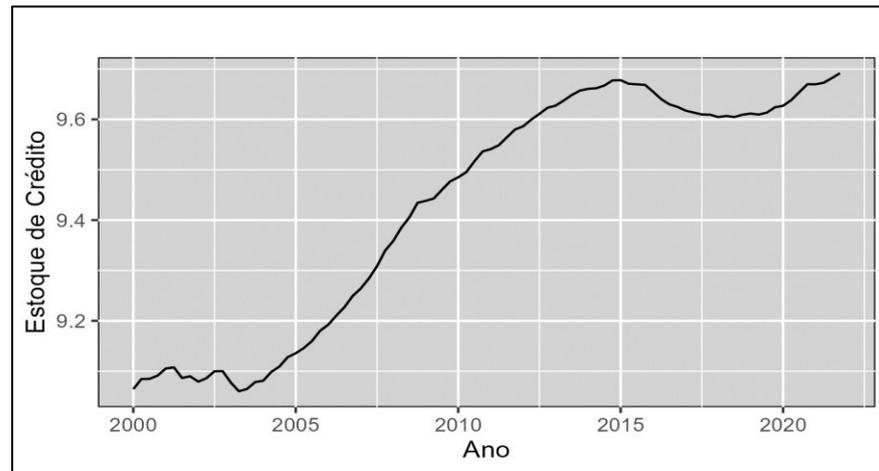
Pretende-se realizar a previsão do estoque de crédito para os quatro trimestres de 2022. Para isso, divide-se a base de dados em dois períodos:

- Período amostral: primeiro trimestre de 2000 ao quarto trimestre de 2021;
- Período de validação: primeiro trimestre de 2022 ao quarto trimestre de 2022.

A série em estudo foi deflacionada pelo Índice Nacional de Preços ao Consumidor Amplo (IPCA), em variação mensal. Para análise dos dados, foi utilizado o software estatístico R.

Na Figura 12 observa-se a evolução do logaritmo do Saldo de das Operações de Crédito do Sistema Financeiro Nacional. Os dados estão deflacionados e correspondem ao período entre o primeiro trimestre de 2000 até o quarto trimestre de 2021. O comportamento da série indica que há tendência de crescimento do saldo de crédito ao longo do tempo, principalmente entre meados de 2004 até o ano de 2015. Esse período se destacou pelo avanço do crédito como proporção do PIB na economia brasileira, conforme destacado na Figura 2. Entre 2015 e 2019, há um recuo do saldo de crédito. Esse período foi marcado pela redução do crédito direcionado, sobretudo pelas menores concessões de financiamento por parte do BNDES. De 2020 a 2022 há uma nova tendência de crescimento do crédito. Esse período foi marcado pelos programas de crédito do Governo Federal para auxiliar empresas durante o período mais agudo da Pandemia de Covid-19.

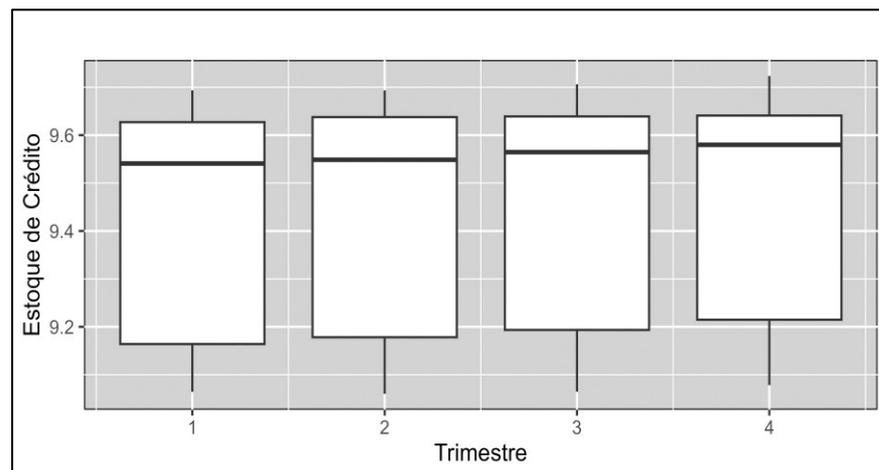
Figura 12 - Série histórica do estoque de crédito – em logaritmo



Fonte: Elaborado pelo autor.

Por sua vez, o gráfico do tipo Box-plot por trimestre (Figura 13) aponta um desalinhamento entre as medianas, sendo que a mediana do quarto trimestre do conjunto de dados é maior que nos demais trimestres, indicando uma possível sazonalidade. Nesse sentido, no último trimestre do ano, há uma tendência de aumento nas concessões de crédito, o que pode estar relacionado aos financiamentos voltados ao aumento de produção e do consumo que ocorrem no período de fim de ano.

Figura 13 - Concessão de Crédito por trimestre

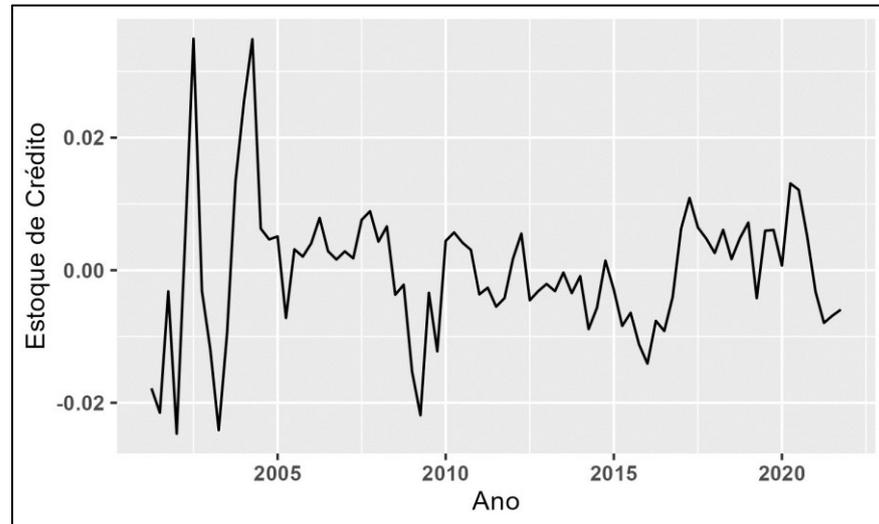


Fonte: Elaborado pelo autor.

Portanto, pela análise gráfica, podemos identificar que a série apresenta tendência determinística crescente e possível sazonalidade, sendo necessário, seguindo a metodologia de Box-Jenkins, tomar uma diferença simples e uma diferença sazonal, com o objetivo de tornar a série estacionária.

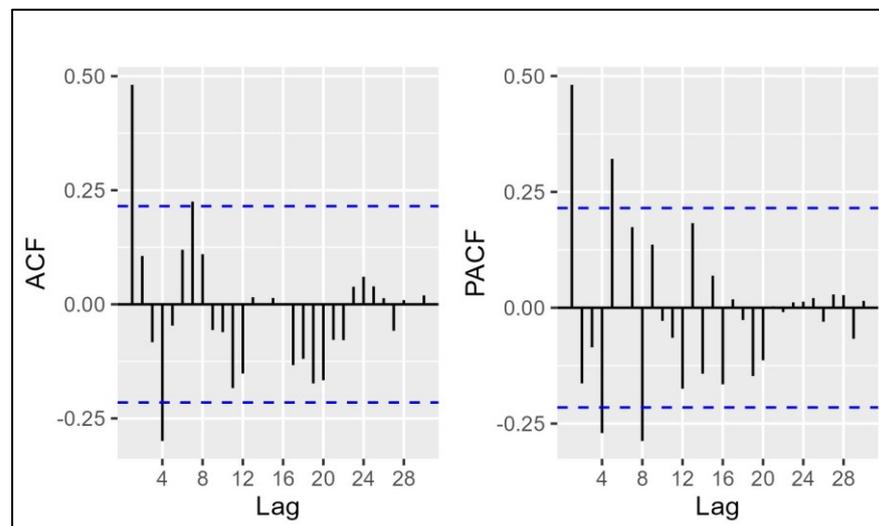
Pelas Figuras 13, se evidenciou a sazonalidade no quarto trimestre, sendo necessário aplicar uma diferença sazonal, considerando possível sazonalidade de ordem quatro.

Figura 14 - Aplicando uma diferença simples e uma sazonal



Fonte: Elaborado pelo autor.

Figura 15 - Correlogramas FAC e FACP da série diferenciada



Fonte: Elaborado pelo autor.

Ao se aplicar uma diferença simples e sazonal, observou-se que a série variou em torno de zero (Figura 14), sendo este um indício de estacionariedade. Para confirmar essa hipótese, realizamos o teste de raiz unitária de Dickey-Fuller. Pelos resultados do teste apresentados na Figura 16, conclui-se que os coeficientes relativos às defasagens 1 e 4 são significativos. Adicionalmente, a estatística do teste de raiz unitária (-3,3301) apresenta um valor acima dos valores críticos do teste (α

1%: -2,6; α 5%:-1,95 e α 10%: -1,61). Portanto, rejeitamos a hipótese nula de raiz unitária na série.

Figura 16 – Resultados Teste de Raiz Unitária de Dickey-Fuller

```
#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####
Test regression none

Call:
lm(formula = z.diff ~ z.lag.1 - 1 + z.diff.lag)
Residuals:
      Min       1Q   Median       3Q      Max
-0.0179646 -0.0037562  0.0005189  0.0039078  0.0231338
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
z.lag.1      -0.53597    0.16094   -3.330  0.00136 **
z.diff.lag1   0.22427    0.12943    1.733  0.08738 .
z.diff.lag2  -0.02968    0.12494   -0.238  0.81291
z.diff.lag3   0.07311    0.10562    0.692  0.49101
z.diff.lag4  -0.31264    0.09745   -3.208  0.00198 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.007459 on 73 degrees of freedom
Multiple R-squared:  0.4246,    Adjusted R-squared:  0.3851
F-statistic: 10.77 on 5 and 73 DF,  p-value: 8.854e-08
Value of test-statistic is: -3.3301
Critical values for test statistics:
      1pct  5pct 10pct
tau1 -2.6 -1.95 -1.61
```

Fonte: Elaborado pelo autor.

Após tornar a série estacionária, deve-se utilizar os correlogramas FAC e FACP para verificar qual ou quais poderiam ser os modelos preliminares para ajuste da série.

Ajustou-se dois modelos. O primeiro modelo encontrado, Modelo 1, foi um SARIMA (0,1,1) (0,1,1) [4], considerando o primeiro lag significativo tanto na parte simples quanto na parte sazonal e o decaimento exponencial alternado na FACP. O segundo, Modelo 2, SARIMA (1,2,1) (0,0,2) [4], foi escolhido por meio da função Auto Arima do programa estatístico R. Essa função realiza uma busca exaustiva pelos modelos ARIMA possíveis dentro de um determinado intervalo de valores para p, d e q. Ela considera diferentes combinações de valores e seleciona o modelo com o menor valor de AIC ou BIC.

Modelo 1: SARIMA (0,1,1) (0,1,1) [4]

O modelo 1 pode ser descrito como:

$$(1 - B)(1 - B^4)(1 - \theta B^4)(Y_t - \mu) = (1 + \theta B)(1 + \theta B^4)$$

$$Y_t = \mu + \varepsilon_y - \theta_1 \varepsilon_{t-1} - \theta_4 \varepsilon_{t-4} - \theta \varepsilon_{t-4}$$

Figura 17 - Resultados da Estimação – Modelo 1

```

z test of coefficients:

              Estimate Std. Error z value Pr(>|z|)
ma1    0.746686    0.093887    7.9530 1.82e-15 ***
sma1  -0.509296    0.117853   -4.3214 1.55e-05 ***
---
Signif. codes:
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

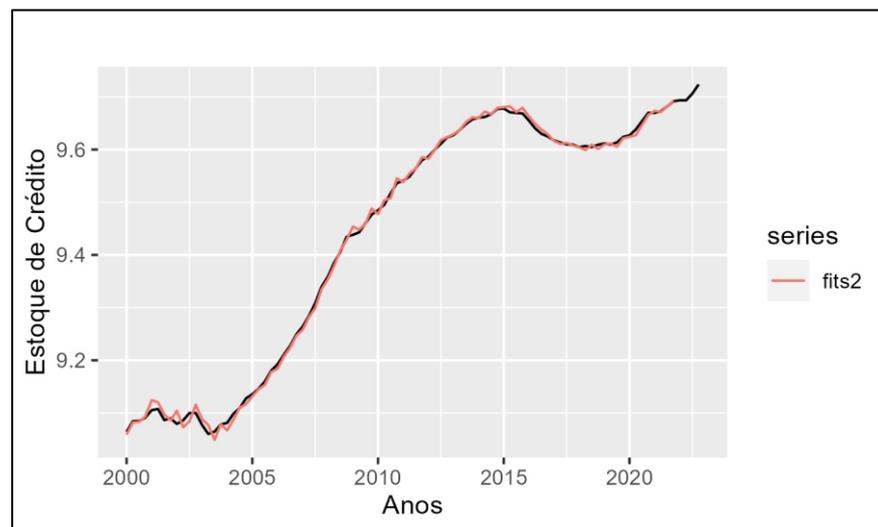
```

Fonte: Elaborado pelo autor.

A análise da Figura 17 aponta que os coeficientes do MA simples e sazonal são estatisticamente significativos (valor-p < 5%). Vale ressaltar que ambos cumprem a condição de invertibilidade uma vez que $-1 < \theta < 1$.

O Modelo 1 ajustou-se bem a variabilidade da série no período entre o primeiro trimestre de 2000 e o quarto trimestre de 2021 (Figura 17).

Figura 18 - Valores ajustados da série – Modelo 1



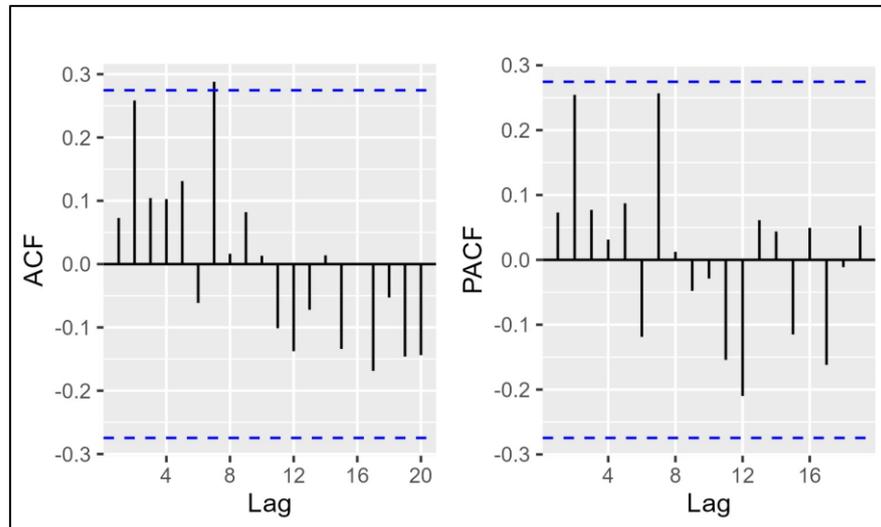
Fonte: Elaborado pelo autor.

Nesse sentido, avança-se para a análise dos resíduos do modelo.

Os correlogramas apontam que há correlação significativa entre os termos de erro (Figura 19). Adicionalmente, a partir da estatística do teste de Box-Ljung (Tabela

3), rejeitamos a hipótese nula de não autocorrelação dos resíduos ao nível de significância de $\alpha = 5\%$.

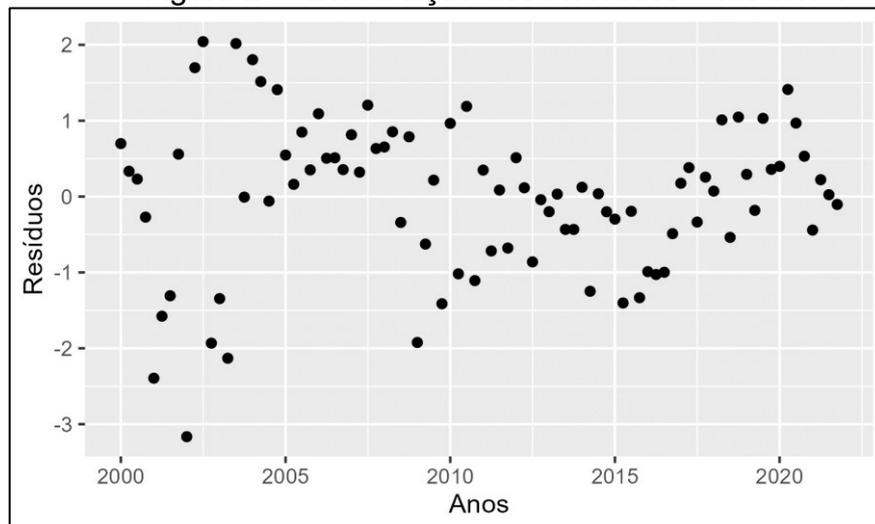
Figura 19 - Correlogramas FAC e FACP dos Resíduos – Modelo 1



Fonte: Elaborado pelo autor.

Pela análise da Figura 20, pode-se identificar que a distribuição dos resíduos aponta para a existência de padrão, em que, apesar de distribuídos em torno de zero, há uma alta variabilidade dos valores nos anos iniciais.

Figura 20 - Distribuição dos Resíduos – Modelo 1



Fonte: Elaborado pelo autor.

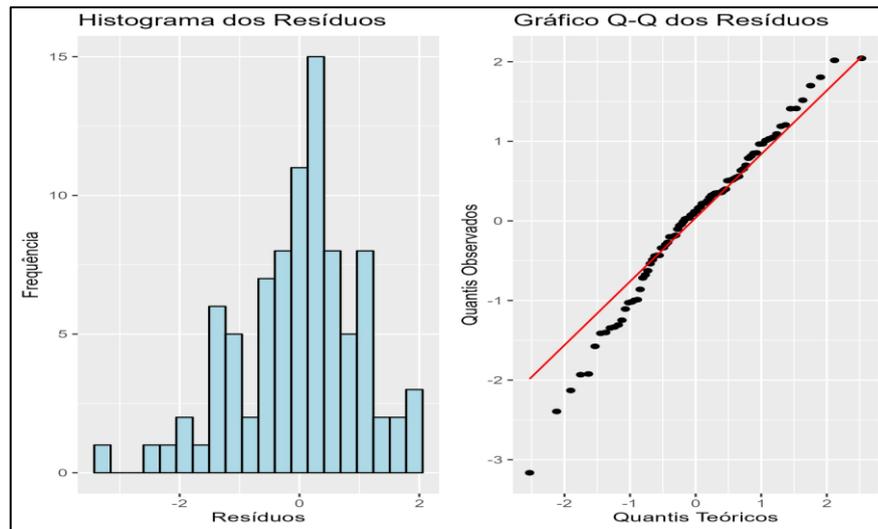
A partir da análise das estatísticas de Shapiro-Wilk e Anderson-Darling (Tabela 3) e do histograma e do Normal Q-Q Plot (Figura 21) dos resíduos, constata-se que os erros seguem uma distribuição normal, no entanto, não podemos dizer que se tratar de um ruído branco.

Tabela 3 - Testes de Normalidade e Autocorrelação dos resíduos – Modelo 1

Teste	Coefficiente	P-valor
Shapiro-Wilk	0,979	0,164
Anderson-Darling	0,598	0,117
Box-Ljung	33,367	0,03074

Fonte: Elaborado pelo autor.

Figura 21 – Histograma e QQ Plot dos Resíduos – Modelo 1



Fonte: Elaborado pelo autor.

Modelo 2: SARIMA (1,2,1) (0,0,2) [4]

O modelo 2 pode ser descrito como:

$$(1 - \phi B)(-1B^4)(1 - B^4)(1 - \theta B^4)(Y_t - \mu) = (1 + \theta B + \theta_2 B^2)(1 + \theta B^4 + \theta_2 B^8)\varepsilon_y$$

$$Y_t = \phi_1 Y_{t-1} + Y_{t+4} - \phi_1 Y_{t-5} + Y_{t-8} - \phi_1 Y_{t-9} + \theta_1 Y_{t-4} - \theta_1 Y_{t-8} + \theta_1 Y_{t-12} - \theta_1 Y_{t-16} \\ - \theta_2 Y_{t-20} + \theta_2 Y_{t-24} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \theta_1 \varepsilon_{t-4} + \theta_2 \varepsilon_{t-8}$$

Figura 22 - Resultados da Estimação - Modelo 2

```
z test of coefficients:

      Estimate Std. Error  z value  Pr(>|z|)
ar1   0.540416   0.110638   4.8845  1.037e-06 ***
ma1  -0.983548   0.085036  -11.5663 < 2.2e-16 ***
sma1  0.411474   0.116139   3.5429  0.0003957 ***
sma2  0.295249   0.110669   2.6679  0.0076336 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Fonte: Elaborado pelo autor.

A análise da Figura 22 aponta que os coeficientes simples e sazonais são estatisticamente significativos (valor-p < 5%). No entanto, a componente média móvel simples – MA (1) não cumpre a condição de invertibilidade, sendo o coeficiente aproximadamente igual a 1 (-0,983548).

Nesse sentido, é importante ressaltar que a função Auto Arima do software R é uma ferramenta útil para a seleção automatizada de modelos ARIMA com base em critérios estatísticos, como o AIC (Critério de Informação de Akaike) ou o BIC (Critério de Informação Bayesiano).

No caso específico mencionado, o Modelo 2 não cumpriu essa restrição fundamental de invertibilidade no componente de médias móveis. Isso significa que o modelo não pode ser utilizado de forma adequada para análise ou previsão.

Modelo 3: SARIMA (1,1,0) (0,1,1) [4]

O Modelo 3 pode ser escrito como:

$$(1 - \phi_1 B)(1 - B)(Y_t - \mu) = (1 - \Theta_1 B^4)(\varepsilon_t - \theta_1 \varepsilon_{t-1})$$

$$Y_t = (1 - \phi_1 B)(1 - B)^{-1}(1 - \Theta_1 B^4)(\varepsilon_t - \theta_1 \varepsilon_{t-1}) + \mu$$

A análise da Figura 23 aponta que os coeficientes do AR (1) simples MA (1) sazonal são estatisticamente significativos (valor-p < 5%). Vale ressaltar que o AR (1) cumpre a condição de estacionariedade ($-1 < \phi < 1$), enquanto o MA (1) a condição de invertibilidade ($-1 < \theta < 1$).

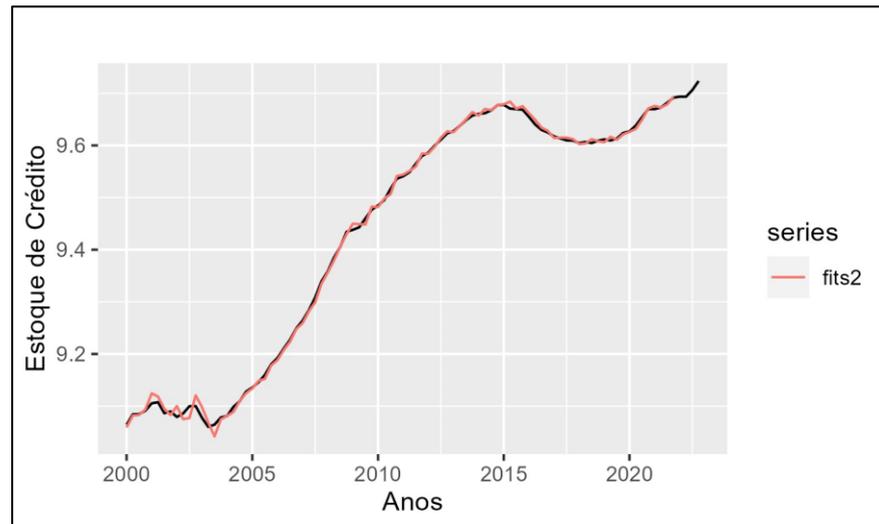
Figura 23 - Resultados da Estimação - Modelo 3

```
z test of coefficients:
      Estimate Std. Error z value Pr(>|z|)
ar1   0.722851   0.082688   8.7419 < 2.2e-16 ***
sma1 -0.880308   0.114440  -7.6923 1.445e-14 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Fonte: Elaborado pelo autor.

O Modelo 3 ajustou-se bem a variabilidade da série no período entre o primeiro trimestre de 2000 e o quarto trimestre de 2021 (Figura 24).

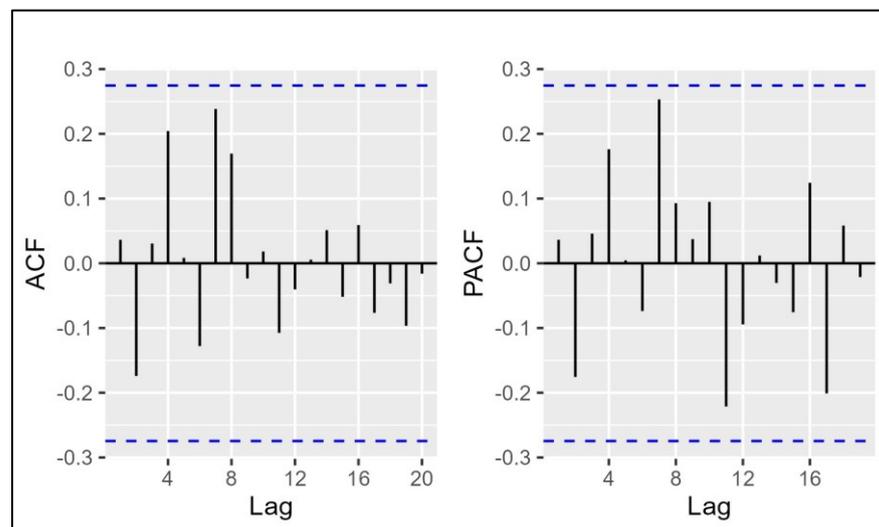
Figura 24- Valores ajustados da série – Modelo 3



Fonte: Elaborado pelo autor.

Por sua vez, os correlogramas apontam que não há correlações significativas entre os termos de erro (Figura 25). Adicionalmente, a partir da estatística do teste de Box-Ljung (Tabela 4), não rejeitamos a hipótese nula de não autocorrelação dos resíduos ao nível de significância de $\alpha = 5\%$

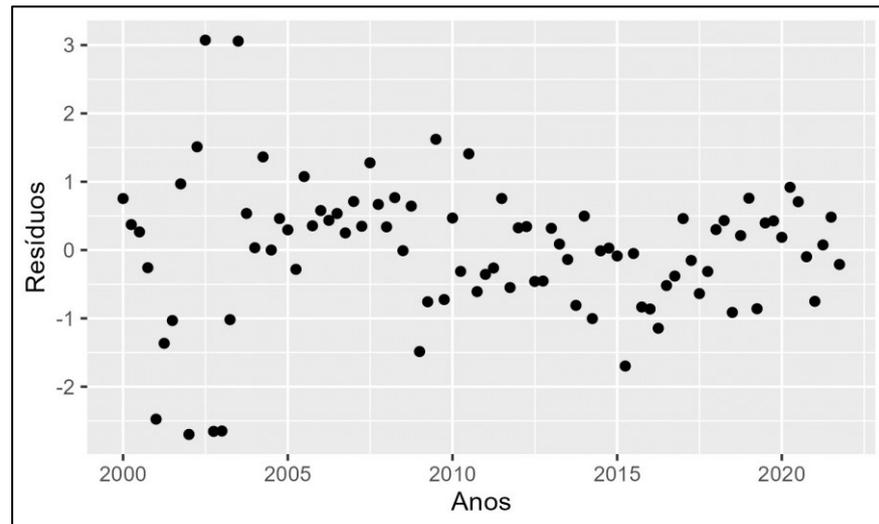
Figura 25 - Correlogramas FAC e FACP dos Resíduos – Modelo 3



Fonte: Elaborado pelo autor.

Pela análise da Figura 26, pode-se identificar que a distribuição dos resíduos não aponta para a existência de padrão. Nesse sentido, os erros podem ser classificados como ruído branco, com média zero $E[\varepsilon_t] = 0$ e variância constante $Var(\varepsilon_t) = \sigma_\varepsilon^2$.

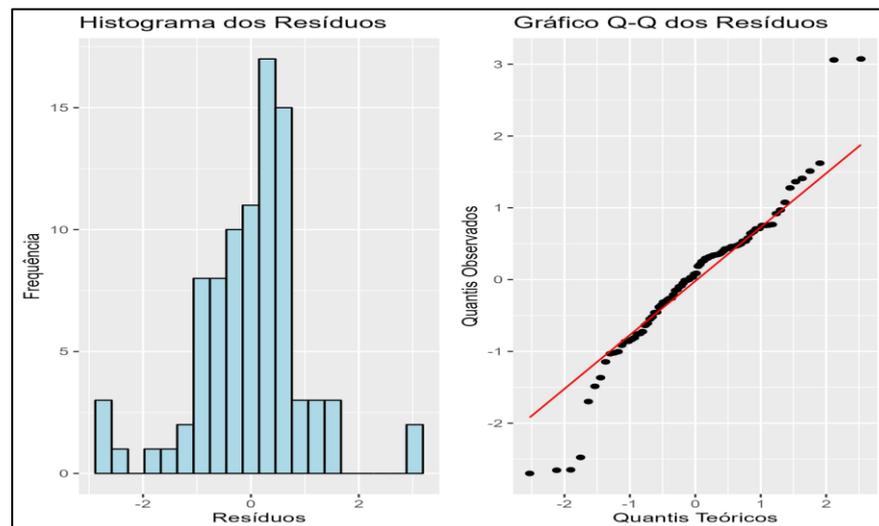
Figura 26 - Distribuição dos Resíduos – Modelo 3



Fonte: Elaborado pelo autor.

Adicionalmente, a partir da análise das estatísticas de Shapiro-Wilk e Anderson-Darling (Tabela 4) e do histograma e do Normal Q-Q Plot (Figura 27) dos resíduos, constata-se que os erros não seguem uma distribuição normal.

Figura 27 - Histograma e QQ Plot dos Resíduos – Modelo 3



Fonte: Elaborado pelo autor.

Tabela 4 - Testes de Normalidade e Autocorrelação dos resíduos – Modelo 3

Teste	Coeficiente	P-valor
Shapiro-Wilk	0,945	0,0009
Anderson-Darling	1,38	0,00133
Box-Ljung	21,19	0,3861

Fonte: Elaborado pelo autor.

O modelo escolhido é o Modelo 3, tendo em vista que o Modelo 1 é inviabilizado pela presença de autocorrelação dos resíduos e o Modelo 2 é inviabilizado porque o componente de média móvel do SARIMA (1,2,1) (0,0,2) [4] não cumpre a condição de invertibilidade. Os coeficientes dos modelos e as estatísticas podem ser observados na Tabela 5.

Tabela 5 - Resultados Modelos Saldo das Operações de Crédito

Estadísticas	M1 SARIMA (0,1,1)(0,1,1)[4]	M2 SARIMA (1,2,1)(0,1,2)[4]	M3 SARIMA (1,1,0)(0,1,1)[4]
Estatísticas do Modelo			
Constante	-	-	-
ϕ_1	-	0,5404	0,722851
θ_1	0,746686	-0,9835	-
θ_2	-	-	-
Φ_1	-	-	-
Θ_1	-0,509296	0,4115	-0,880308
Θ_2	-	0,295249	-
MSE	0,007845424	0,00764652	0,007522717
AIC	-562,4797	-582,54	-566,27
BIC	-555,2231	-570,27	-559,01
Estatísticas dos Resíduos			
Média	-0,000275177	-0,000622555	-0,000460754
Desvio padrão	0,007885529	0,007664809	0,007551624
Assimetria	-0,51687	-0,3299321	-0,1464249
Curtoses	3,420717	3.081.928	4,884
Test Normalidade de Arnderson Darling (Valor P)	0,1638053	0,3169717	0,001

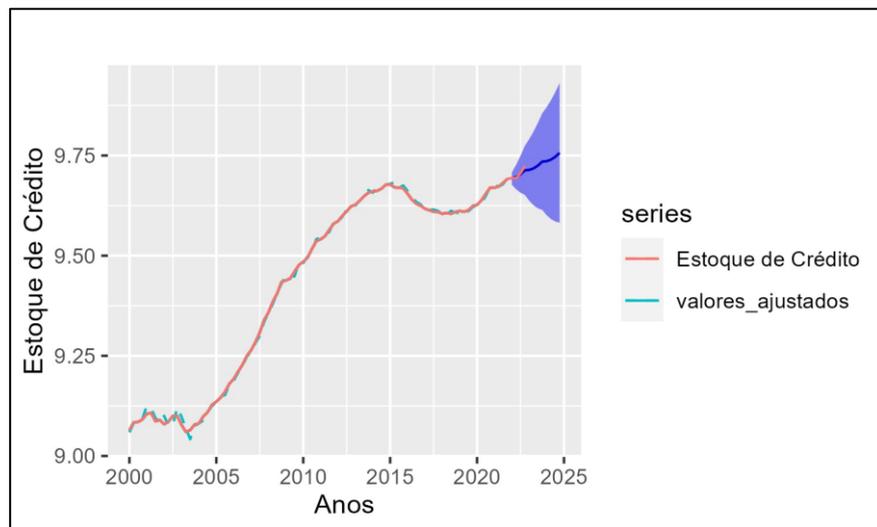
Fonte: Elaborado pelo autor.

O Modelo 3 foi o mais adequado para realizar a previsão do estoque de crédito, tendo em vista a limitação dos demais modelos.

Previsão

Na análise de previsões quatro passos à frente (primeiro ao quarto trimestre de 2022) nota-se que o modelo encontrado acompanhou o comportamento dos valores reais (Figura 28).

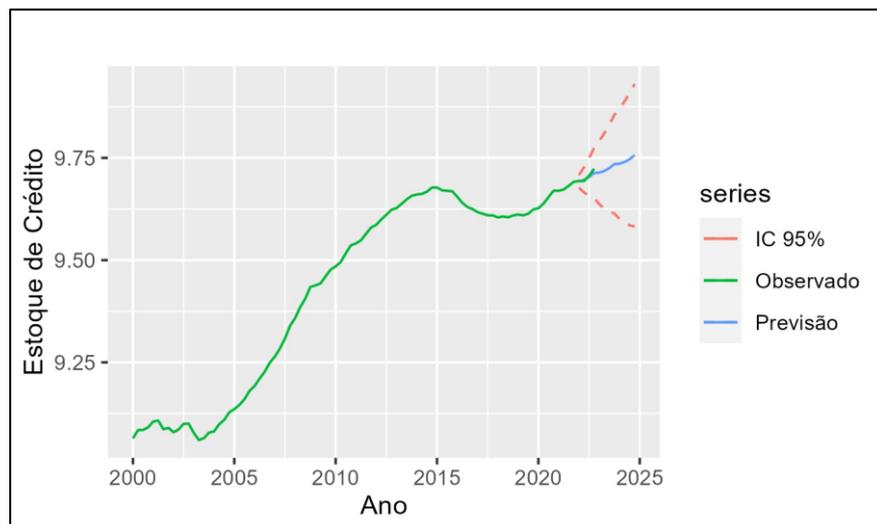
Figura 28 – Estoque de Crédito e Valores Ajustados



Fonte: Elaborado pelo autor.

Adicionalmente, destaca-se que a previsão do modelo quatro passos à frente situou-se dentro do intervalo de 95% de confiança (Figura 29).

Figura 29 - Previsão do estoque de crédito



Fonte: Elaborado pelo autor.

Entre o primeiro e o quarto trimestre de 2022, o estoque de crédito do Sistema Financeiro Nacional avançou de R\$ 4.938 bilhões para R\$ 5.291 bilhões. Os valores previstos pelo Modelo 3 para esse período correspondem a R\$ 4.926 bilhões e R\$ 5.165 bilhões, respectivamente (Tabela 6).

Tabela 6 - Valores reais e previstos do estoque de crédito

Trimestre	Logaritmo		Valores reais (em R\$ bilhões)	
	Real	Previsão	Real	Previsão
1T22	9,69	9,69	4.938	4.926
2T22	9,69	9,69	4.937	4.926
3T22	9,71	9,70	5.084	5.049
4T22	9,72	9,71	5.291	5.165

Fonte: Elaborado pelo autor.

Considerando as estatísticas dos erros de previsão (Tabela 7) o melhor modelo no período amostral foi o Modelo 3. Por sua vez, no período de validação, o Modelo 2 seria o mais adequado. No entanto, considerando sua limitação de raiz unitária, optou-se pelo Modelo 3.

Tabela 7 - Estatísticas dos Erros de Previsão

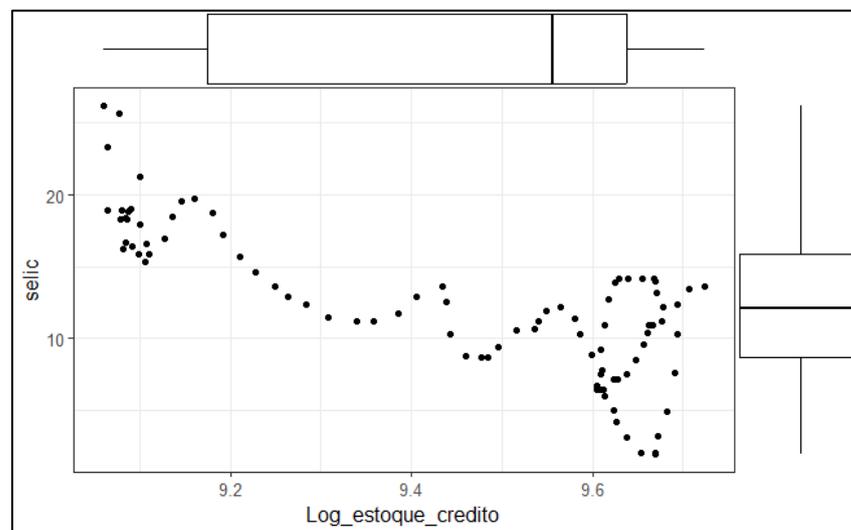
	Período Amostral		
	M1 SARIMA (0,1,1)(0,1,1)[4]	M2 SARIMA(1,2,1)(0,1,2)[4]	M3 SARIMA(1,1,0)(0,1,1)[4]
ME	-0,000275	-0,000623	-0,000461
RMSE	0,007845	0,007647	0,007523
MAE	0,006016	0,005881	0,005451
MPE	-0,002730	-0,006464	-0,004707
MAPE	0,064392	0,063098	0,058394
ACF1	0,072923	0,040308	0,036240
Período de Validação			
ME	0,003409	-0,002367	0,002905
RMSE	0,005274	0,005280	0,005664
MAE	0,004112	0,004652	0,004360
MPE	0,035085	-0,024437	0,029878
MAPE	0,042328	0,047943	0,044886
ACF1	0,050822	-0,097240	0,117442
Theil's U	0,475236	0,486919	0,523500

Fonte: Elaborado pelo autor.

Regressão Dinâmica

Existe um bom comportamento entre o saldo da carteira de crédito nacional e a taxa de juros Selic, expresso por uma correlação positiva -0,781 (Figura 30). É evidente, conforme apontado pela literatura, que existe uma relação negativa e significativa entre a Taxa Selic e o saldo de crédito, ou seja, aumentos da taxa básica de juros são acompanhados por redução nas operações de crédito e, por sua vez, diminuições da taxa de juros são acompanhadas por avanço no saldo de crédito.

Figura 30 - Taxa Selic e Log do Saldo da Carteira de Crédito Nacional



Fonte: Elaborado pelo autor.

Para identificar e evidenciar a relação entre a taxa de juros e o saldo da carteira de crédito, estimou-se três modelos de regressão.

Modelo 4

Nesse modelo o saldo da carteira de crédito nacional é explicado por um termo constante e pela Taxa Selic. Esta última com impactos negativos sobre o crédito, conforme esperado (Figura 31).

O Modelo 4 pode ser escrito como:

$$\text{Estoque de crédito}_t = \beta_0 + \beta_1 \text{Nível Taxa Selic}_t + \varepsilon_t$$

Conforme análise do teste t de Student ($H_0: \beta_1 = 0$; $H_1: \beta_1 \neq 0$), pode-se afirmar que os coeficientes da inclinação são significativos. Adicionalmente, o coeficiente de determinação (R^2) apontou que o modelo explicou 55,2% da variabilidade dos dados.

Figura 31 - Resultados da regressão do Modelo 4

```

Call:
lm(formula = Estoque.de.crédito ~ selic, data = dados)

Residuals:
    Min       1Q   Median       3Q      Max
-1252.7  -701.2  -236.9   541.0  2445.2

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  5592.19     253.59   22.05  <2e-16 ***
selic        -201.17      19.11  -10.53  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 945.6 on 90 degrees of freedom
Multiple R-squared:  0.5518,    Adjusted R-squared:  0.5469
F-statistic: 110.8 on 1 and 90 DF,  p-value: < 2.2e-16

```

Fonte: Elaborado pelo autor.

Contudo, as estatísticas do teste apontaram presença de autocorrelação de ordem 1 nos resíduos, o que inviabiliza o Modelo 1 (Figura 32).

Figura 32 - Teste de Durbin-Watson do Modelo 4

```

Durbin-Watson test

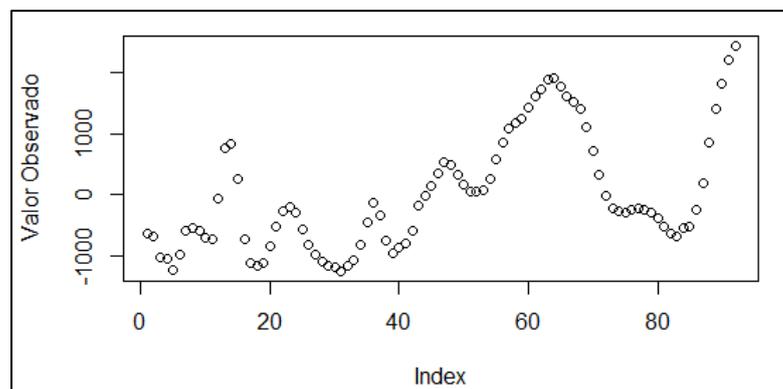
data:  modelo1
DW = 0.085258, p-value < 2.2e-16
alternative hypothesis: true autocorrelation is greater than 0

```

Fonte: Elaborado pelo autor.

A identificação da presença de autocorrelação de ordem 1 dos resíduos é corroborada pela análise gráfica. Identificou-se um comportamento padrão nos termos de erro (Figura 33).

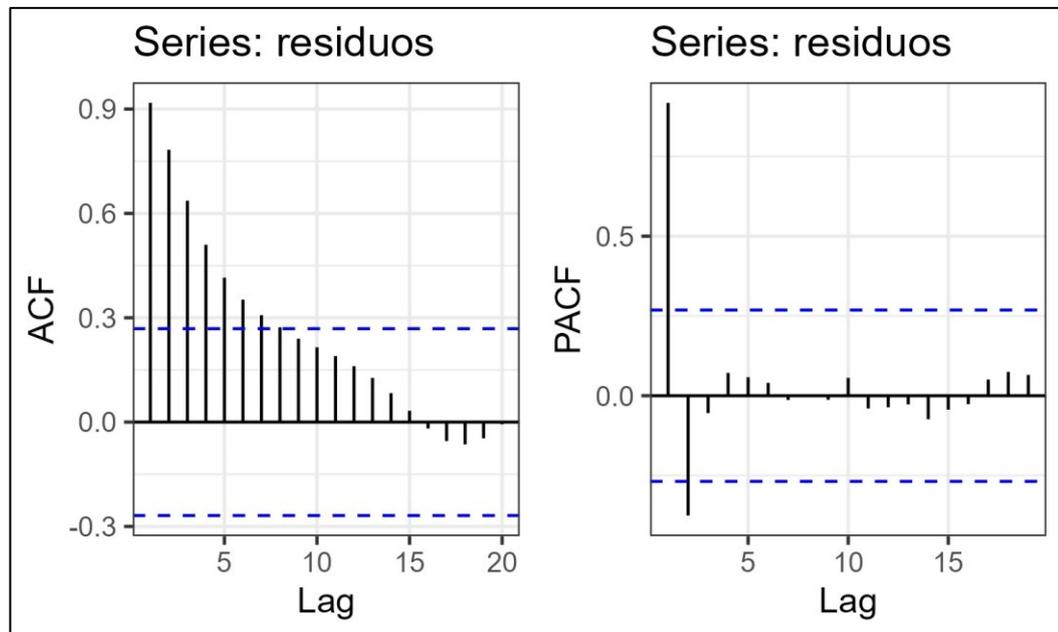
Figura 33 - Distribuição dos Resíduos



Fonte: Elaborado pelo autor.

Adicionalmente, observou-se presença de autocorrelações significativas nos correlogramas FAC e FACP (Figura 34).

Figura 34 - FAC e FACP dos Resíduos



Fonte: Elaborado pelo autor.

Modelo 5

No segundo modelo de regressão dinâmica (Modelo 5), o saldo da carteira de crédito nacional é explicado por um termo constante, pela Taxa Selic e pelos valores defasados da própria variável dependente (Figura 35).

O Modelo 5 pode ser escrito como:

$$\begin{aligned}
 \text{Estoque de crédito}_t &= \beta_0 + \beta_1 \text{Nível Taxa Selic}_t + \beta_2 \text{Estoque de crédito}_{t-1} \\
 &+ \beta_3 \text{Estoque de crédito}_{t-2} + \beta_4 \text{Estoque de crédito}_{t-3} \\
 &+ \beta_5 \text{Estoque de crédito}_{t-4} + \beta_6 \text{Estoque de crédito}_{t-5} \\
 &+ \beta_7 \text{Estoque de crédito}_{t-6} + \varepsilon_t
 \end{aligned}$$

O coeficiente de determinação (R^2) apontou que o modelo explicou 100% da variabilidade dos dados. É importante exercer cautela nessas situações. Embora possa parecer indicar um ajuste de modelo perfeito, é essencial entender que essa situação pode levantar algumas questões e requerer uma análise mais aprofundada.

Vale destacar também que alguns valores defasados da série apresentaram resultados negativos, apontando que algumas defasagens do saldo de crédito contribuem negativamente para o saldo de crédito no período t.

Figura 35 - Resultados da regressão Modelo 5

```
Call:
lm(formula = Estoque.de.crédito ~ selic + Estoque.de.crédito_lag1 +
    Estoque.de.crédito_lag2 + Estoque.de.crédito_lag3 + Estoque.de.crédito_lag4 +
    Estoque.de.crédito_lag5 + Estoque.de.crédito_lag6, data = dados2)

Residuals:
    Min       1Q   Median       3Q      Max
-95.886 -27.046   5.781  21.380 111.923

Coefficients:
                Estimate Std. Error t value Pr(>|t|)
(Intercept)      108.0980    35.1327   3.077 0.002885 **
selic             -4.2320     1.5071  -2.808 0.006295 **
Estoque.de.crédito_lag1  1.5081     0.1148  13.135 < 2e-16 ***
Estoque.de.crédito_lag2 -0.6926     0.1832  -3.780 0.000305 ***
Estoque.de.crédito_lag3  0.2691     0.1950   1.380 0.171557
Estoque.de.crédito_lag4  0.4904     0.1964   2.497 0.014633 *
Estoque.de.crédito_lag5 -0.8677     0.1895  -4.578 1.75e-05 ***
Estoque.de.crédito_lag6  0.2788     0.1125   2.478 0.015356 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 42.21 on 78 degrees of freedom
(6 observations deleted due to missingness)
Multiple R-squared:  0.9991,    Adjusted R-squared:  0.999
F-statistic: 1.252e+04 on 7 and 78 DF,  p-value: < 2.2e-16
```

Fonte: Elaborado pelo autor.

As estatísticas do teste não apontaram presença de autocorrelação de ordem 1 nos resíduos (Figura 36), uma vez que não rejeitamos a hipótese nula ao nível de significância de 5%.

Figura 36 - Teste de Durbin-Watson do Modelo 5

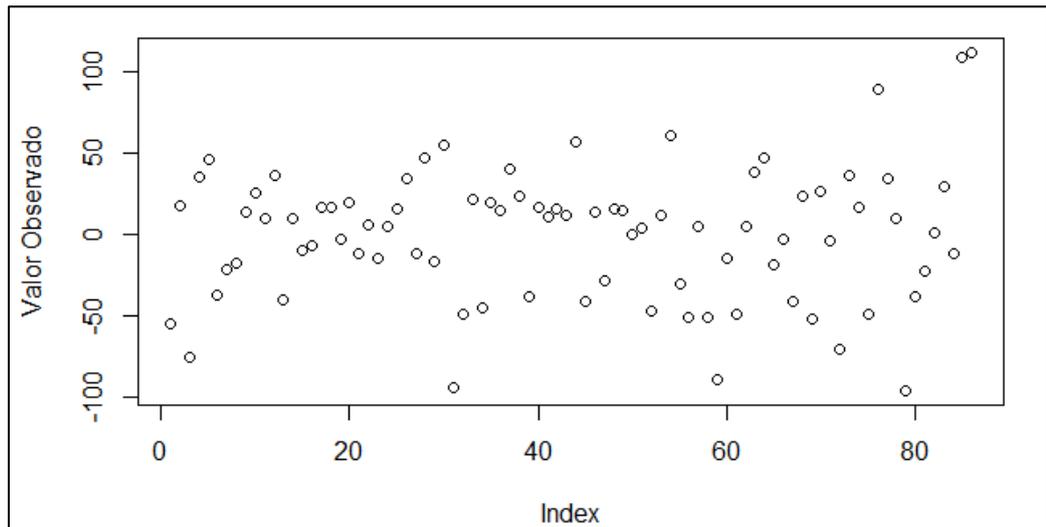
```
Durbin-Watson test

data: modelo5
DW = 1.8738, p-value = 0.1935
alternative hypothesis: true autocorrelation is greater than 0
```

Fonte: Elaborado pelo autor.

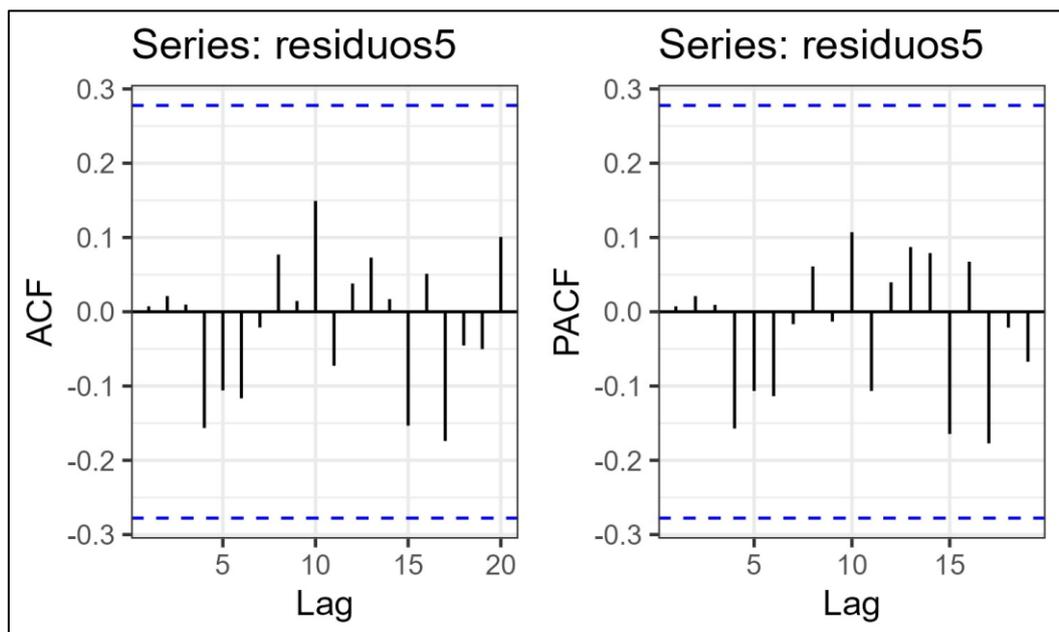
A identificação da não presença de autocorrelação de ordem 1 dos resíduos é corroborada pela análise gráfica. Não se identificou um comportamento padrão nos termos de erro (Figura 37).

Figura 37 - Distribuição dos Resíduos - Modelo 5



Fonte: Elaborado pelo autor.

Figura 38 - FAC e FACP dos Resíduos



Fonte: Elaborado pelo autor.

Adicionalmente, os correlogramas apontam para identificar a não autocorrelação dos termos de erro do Modelo 5 (Figura 38).

Modelo 6

A terceiro modelo de regressão dinâmica (Modelo 6) considerou apenas as variáveis estatisticamente significantes do modelo anterior (Figura 39)

O Modelo 6 pode ser escrito como:

Estoque de crédito_t

$$\begin{aligned}
 &= \beta_0 + \beta_1 \text{Nível Taxa Selic}_t + \beta_2 \text{Estoque de crédito}_{t-1} \\
 &+ \beta_3 \text{Estoque de crédito}_{t-2} + \beta_4 \text{Estoque de crédito}_{t-4} \\
 &+ \beta_5 \text{Estoque de crédito}_{t-5} + \varepsilon_t
 \end{aligned}$$

Figura 39 - Resultados do Modelo 6

```

Call:
lm(formula = Estoque.de.crédito ~ selic + Estoque.de.crédito_lag1 +
    Estoque.de.crédito_lag2 + Estoque.de.crédito_lag4 + Estoque.de.crédito_lag5,
    data = dados2)

Residuals:
    Min       1Q   Median       3Q      Max
-122.325  -19.081    3.626   20.163  131.178

Coefficients:
                Estimate Std. Error t value Pr(>|t|)
(Intercept)      132.75439   34.58256    3.839 0.000244 ***
selic             -5.41532    1.49031   -3.634 0.000489 ***
Estoque.de.crédito_lag1  1.31134    0.09899   13.247 < 2e-16 ***
Estoque.de.crédito_lag2 -0.37415    0.12626   -2.963 0.003994 **
Estoque.de.crédito_lag4  0.57944    0.13062    4.436 2.86e-05 ***
Estoque.de.crédito_lag5 -0.53403    0.09591   -5.568 3.25e-07 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 44.26 on 81 degrees of freedom
(5 observations deleted due to missingness)
Multiple R-squared:  0.999,    Adjusted R-squared:  0.9989
F-statistic: 1.634e+04 on 5 and 81 DF,  p-value: < 2.2e-16

```

Fonte: Elaborado pelo autor.

Os resultados também mostraram algumas defasagens do saldo de crédito com sinal negativo.

Seguindo para as estatísticas do Modelo 6, pelo Teste de Durbin-Watson rejeitamos a hipótese nula de não autocorrelação dos nos resíduos (Figura 40).

Figura 40 - Teste de Durbin-Watson do Modelo 6

```

Durbin-Watson test

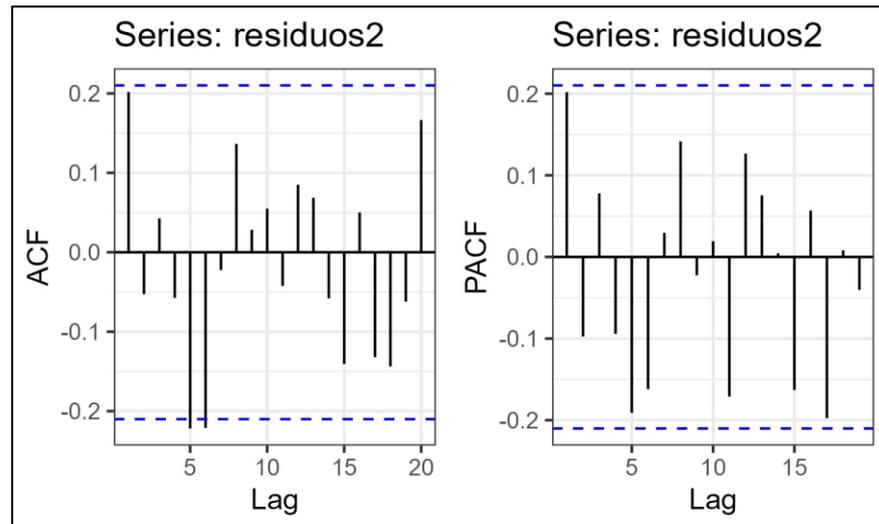
data: modelo2
DW = 1.4681, p-value = 0.002226
alternative hypothesis: true autocorrelation is greater than 0

```

Fonte: Elaborado pelo autor.

A identificação da presença de autocorrelação de ordem 1 dos resíduos é corroborada pela análise dos correlogramas FAC e FACP (Figura 41).

Figura 41 - FAC e FACP dos Resíduos



Fonte: Elaborado pelo autor.

Nesse sentido, apesar dos modelos, conforme esperado, apresentar o impacto negativo da Selic no estoque de crédito, nenhum deles apresentou resultados satisfatórios. Diferente de outros Modelos, o Modelo 5, que não apresentou autocorrelação dos resíduos, registrou um R^2 elevado (100%). Embora possa parecer indicar um ajuste de modelo perfeito, é essencial entender que essa situação pode levantar algumas questões e requerer uma análise mais aprofundada.

7 CONCLUSÃO

O presente estudo teve como objetivo propor modelos de previsão para o comportamento do saldo de crédito do Sistema Financeiro Nacional, bem como avaliar a relação entre o crédito e a Taxa Selic. Para tanto, utilizou-se de modelos univariados de previsão, por meio da modelagem da própria variável. Já a relação entre o saldo de crédito e a Taxa Selic foi estimada por meio de modelos de regressão dinâmica.

As variáveis possuem periodicidade trimestral e compreendem o primeiro trimestre de 2000 ao quarto trimestre de 2022. Para os modelos de previsão, foram construídos três modelos SARIMA. O terceiro, SARIMA (1,1,1)(0,1,1)[4], mostrou-se como o melhor modelo para acompanhar a variabilidade da série. O saldo da carteira de crédito no SFN foi de R\$ 4.938 bilhões. A previsão do Modelo 3 para o período foi de R\$ 4,926 bilhões.

Na estimação por meio da regressão dinâmica, considerou-se o Modelo 5 como o mais adequado, já que os outros dois apresentaram autocorrelação de ordem 1 nos resíduos. Contudo, destaca-se R^2 elevado (100%) que, embora possa parecer indicar um ajuste de modelo perfeito, é essencial entender que essa situação pode levantar algumas questões e requerer uma análise mais aprofundada. O resultado aponta para a possibilidade da inclusão de outras variáveis explicativas no modelo.

Conclui-se que os modelos univariados se mostraram eficazes na previsão do saldo de crédito do Sistema Financeiro Nacional. Adicionalmente, observou-se, por meio da estimação, que a variável dependente é negativamente influenciada pela Selic, conforme apontado pela literatura.

Nesse sentido, vale destacar a relevância do estudo para contribuir no entendimento do comportamento da variável de crédito e sua relação com a Taxa Selic, sobretudo após as mudanças ocorridas nos últimos anos, como a substituição da TJLP pela TLP e o recuo do crédito direcionado na economia.

9 REFERÊNCIAS

ARRAIS, Samuel Santos Camelo. 2019. **Modelo de previsão do ICMS do Estado do Ceará: Aplicação da Metodologia Box-Jenkins**. Universidade Federal do Ceará.

BANCO CENTRAL DO BRASIL. **Relatório de Inflação: Potência da política monetária**. Brasília, DF, 2020. 28 p. (Estudo Especial, n. 77).

BANCO CENTRAL DO BRASIL. **Relatório de Inflação: Modelo agregado de pequeno porte – 2017**. Brasília, DF, 2017. 53 p.

BANCO CENTRAL DO BRASIL. Relatório Focus. Brasília, 2023a. Disponível em: <https://www.bcb.gov.br/publicacoes/focus>. Acesso em: 05 abr. 2023.

BARBOZA, Ricardo, M. **Taxa de juros e mecanismos de transmissão da política monetária no Brasil**. Revista de Economia Política, v. 35, n. 1, p. 133-155, 2015.

BEVILAQUA, A.; MESQUITA, M. e MINELLA, A. **“Brazil: Taming Inflation Expectations”**, BCB Working Papers, Nº 129, 2007.

BOGDANSKI, Joel; TOMBINI, Alexandre; WERLANG, Sérgio. **Implementing inflation targeting in Brazil**. Working Paper Series, Banco Central do Brasil, Brasília, n. 1, p. 1-29, jul. 2000.

BONOMO, Marco; MARTINS, Bruno. **The impact of government-driven loans in the monetary transmission mechanism: what can we learn from firm-level**. Working Paper Series, Banco Central do Brasil, Brasília, n. 419, p. 1-29, mar. 2016.

BUENO, R. L. S. *Econometria de Séries Temporais*. São Paulo: Cengage Learning, 2008.

CAVALCANTI, M. **IDENTIFICAÇÃO DE MODELOS VAR E CAUSALIDADE DE GRANGER: UMA NOTA DE ADVERTÊNCIA**. Instituto de Pesquisa Econômica Aplicada – Rio de Janeiro. Aceito em 18 de junho de 2010.

CLEITON Silva de Jesus. **Revisitando a potência da política monetária no Brasil**. Universidade Estadual de Feira de Santana. Professor do DCIS/UEFS, Pesquisador do GEMA e Tutor do PET Economia (MEC/SESU).

DA SILVA, Marcelo E. A.; PORTUGAL, Marcelo S. **Inflation targeting in Brazil: an empirical evaluation**. Revista de Economia, Banco Central Del Uruguay, v. IX, n. 2, p. 86-122, nov. 2002.

ENDERS, W. **Applied econometric time series**. 3. ed. New Jersey: Wiley, 2010.

MORETTIN, Pedro Alberto; TOLOI, Clélia Maria de Castro. **Análise de séries temporais**. São Paulo: Edgard Blucher, 2004.

EPIFÂNIO, B. S. **Modelos para Previsão do Índice de Produção Física de Minas Gerais**. Monografia (Especialização em Estatística) - Universidade Federal de Minas Gerais, 2015.

Freitas, P. S. & Muinhos, M. K. (2001). **A simple model for inflation targeting in Brazil**. Central Bank of Brazil, Working Paper Series, no. 18.

GUJARATI, D. N.; PORTER, D. C. **Econometria básica**. 5. ed. São Paulo: AMGH Editora, 2012.

Joel Bogdanski & Alexandre Antonio Tombini & Sérgio Ribeiro da Costa Werlang, 2000. **"Implementing Inflation Targeting in Brazil,"** Working Papers Series 1, Central Bank of Brazil, Research Department.

JOSÉ, M.; DE SOUZA, S. [s.l: s.n.]. Disponível em: <https://bdm.unb.br/bitstream/10483/19925/1/2017_MatheusJos%C3%A9SilvadeSouza.pdf>. Acesso em: 26 fev. 2023.

MARCATTI, Fernanda. **Evolução da eficiência do canal de crédito na política monetária brasileira**. 2011. 49 p. Dissertação (Mestrado em Finanças e Economia) – Escola de Economia de São Paulo, Fundação Getulio Vargas, São Paulo, 2011.

MARGARIDO, M, A.; **Teste de cointegração de Johansen utilizando o SAS. Agric.** São Paulo, São Paulo, v. 51, n. 1, p. 87-101, jan./jun.2004.

Mattos, R. S. (2022). **Breve recordação de polinômios para estudo de modelos ARIMA**. Dissertação de Mestrado, Universidade Federal de Juiz de Fora, Departamento de Economia.

MINELLA, André et al. **Inflation targeting in Brazil: lessons and challenges**. Working Paper Series, Banco Central do Brasil, Brasília, n. 53, p. 1-47, nov. 2002.

OECD (2022), **OECD Economic Outlook**, Volume 2022 Issue 2, OECD Publishing, Paris, <https://doi.org/10.1787/f6da2159-en>.

R. DE CASTRO, M. et al. SAMBA: **Stochastic Analytical Model with a Bayesian Approach**. Disponível em: <<https://www.bcb.gov.br/pec/wps/ingl/wps239.pdf>>. Acesso em: jun. 2011.

ROCHA, Francisco José Sales. **Metodologia Box-Jenkins de escolha de modelos de séries temporais sazonais: um estudo do comportamento temporal da produção física industrial (PFI) de Pernambuco**. Revista Economia & Gestão, v.3, p.10-20, 2002.

SIMS, C. **MACROECONOMICS AND REALITY**. Econometrica, v.48, p.1-48, janeiro de 1980. Disponível em:<https://www.pauldeng.com/pdf/Sims%20macroeconomics%20and%20reality.pdf>. Acesso em 14 de março de 2023.

SOUZA, Gueibi Peres de. **Previsão do consumo industrial de energia elétrica no estado de Santa Catarina: uma aplicação da combinação de previsões entre modelos univariados e de regressão dinâmica.** 2015. Dissertação (Mestrado em Energia) - Universidade Federal de Santa Catarina.

TOSCANO, E. M. M. **Análise de Séries Temporais - Modelos ARMA.** Belo Horizonte: Apostila do Curso de Especialização em Estatística da UFMG, 2022.

VARIAN, H. R. Microeconomia: **Princípios Básicos. Uma Abordagem Moderna.** Tradução da 7ª edição. Tradução de Maria José Cyhlar Monteiro e Ricardo Doninelli.