



Jéssica Fernandes de Araujo

Análise dos indicadores de crédito brasileiro

Brasília - DF

2021

Jéssica Fernandes de Araujo

Análise dos indicadores de crédito brasileiro

Dissertação apresentada ao Programa de Pós-Graduação em Administração da Universidade de Brasília para obtenção do título de Mestre em administração.

Universidade de Brasília
Faculdade de Administração, Contabilidade e Economia
Departamento de Administração

Orientador: Herbert Kimura

Brasília - DF
2021

Análise dos indicadores de crédito brasileiro/ Jéssica Fernandes de Araujo.

Brasília - DF, 2021

98 p.; 30 cm

Orientador: Herbert Kimura

DISSERTAÇÃO – Universidade de Brasília
Faculdade de Administração, Contabilidade e Economia
Departamento de Administração

1. INDICADORES DE CRÉDITO 2. SÉRIES TEMPORAIS 3. QUEBRAS
ESTRUTURAIS 4. ELASTICIDADE DA DEMANDA 5. PANDEMIA

Jéssica Fernandes de Araujo

Análise dos indicadores de crédito brasileiro

Dissertação apresentada ao Programa de Pós-Graduação em Administração da Universidade de Brasília para obtenção do título de Mestre em administração.

Data da defesa: 25 de novembro de 2021.

Orientador:

Prof. Herbert Kimura

Comissão Examinadora:

Prof. Raul Matsushita

Prof. Leonardo Basso

Brasília - DF

2021

Aos meus melhores amigos, P.R. e Dan.

Agradecimentos

Esse título é resultado da contribuição de muitas pessoas em minha vida.

Ao meu orientador, Kimura, por não me deixar desistir em meio à suspensão de acesso aos dados por conta da pandemia. Pensamos em um plano B e começamos tudo de novo.

Parte desse plano B só foi possível graças às inúmeras sugestões de um profissional incrível, João De Negri, e de um colega de muitos anos, Cayan. Sem vocês, eu não teria uma dissertação.

Aos membros da banca, Raul e Leonardo, primeiramente, pela aprovação do meu trabalho e também por todas as críticas sugeridas.

Ao meu parceiro de vida, Paulo Renato, por me incentivar em todos os momentos em que me faltaram motivação, tempo e energia. Obrigada por acreditar em mim!

À minha principal torcida: Márcia, Rick e Cris. Amo vocês!

À minha melhor amiga, Amanda, por oferecer o ombro amigo mais acolhedor todas as vezes que precisei.

Ao meu motivo de respirar, Danillo, por entender todas as vezes que não pude jogar bola com ele, pois pensava que o mestrado era mais um emprego da mamãe.

Resumo

O conjunto de informações de crédito de um país funciona como um indicador de crescimento econômico — já que influencia o consumo, o investimento e a inovação dentre pessoas, empresas, organizações e nações. A proposta deste projeto é avaliar a trajetória do crédito brasileiro, historicamente e também com foco no período da pandemia global da Covid-19. As séries de dados advêm do SGS do Banco Central do Brasil e variam de janeiro de 2013 a junho de 2021. Dado a recente divulgação desses dados, abril de 2017, este trabalho têm caráter singular na literatura econométrica.

O primeiro estudo consiste em legitimar os choques advindos de crises econômicas/políticas/sociais no custo do crédito através da análise de quebras estruturais. Os picos de pontos de mudança encontrados sugerem efeitos negativos da crise econômica brasileira de 2015 a 2017 e efeitos positivos da pandemia da Covid-19 no mercado de crédito.

O segundo estudo consiste em analisar as elasticidades prazo e juros da demanda de crédito total e também segmentado por crédito livre e direcionado. Os resultados sugerem que o alongamento dos prazos influencia positivamente a demanda por empréstimos e a taxa de juros, negativamente. Mas essa afirmativa não é válida para o crédito direcionado, onde os juros tem elasticidade positiva.

O terceiro estudo consiste em avaliar se os impactos das ações governamentais e bancárias durante a pandemia da Covid-19 teriam mudado a tendência dos indicadores de crédito. Através de modelos de séries temporais, são avaliados fatores dos empréstimos como: saldo, prazo, ICC, *spread*, inadimplência e taxa de juros. De fato, não eram esperadas quedas tão acentuadas para o ICC, *spread*, taxa de juros e principalmente para a inadimplência, onde o cenário previsto era de estabilidade. Os prazos foram prolongados e o saldo total cresceu ainda mais. Estas variações positivas podem ser explicadas pelo impulso do Auxílio Emergencial e programas de incentivo ao crédito lançados no primeiro semestre de 2020.

Palavras-chaves: Indicadores de crédito. Séries temporais. Quebras estruturais. Elasticidade da demanda. Pandemia.

Abstract

A country's set of credit information works as an indicator of economic growth — since it influences consumption, investment and innovation among people, companies, organizations and other nations. The present project evaluates the trajectory of Brazilian credit, both historically and during the Covid-19 global pandemic. The data comes from the SGS of the Central Bank of Brazil and covers the period from January 2013 to June 2021. Given the recent release of these data, April 2017, this work gains a unique importance within the econometric literature.

The first legitimizes shocks caused by economic/political/social crises in the cost of credit through structural breaks analysis. In relation to the credit market, the peaks of turning points that were found suggest negative effects caused by the Brazilian economic crisis between 2015 and 2017, and also positive outcomes from the Covid-19 pandemic.

The second study analyzes the elasticities of payment terms and interest rate of the total credit demand and also segmented by private and public credits. The obtained results suggest that prolonging payment terms positively influences the search for loans, whereas the interest rate has a negative impact. But this statement is not valid for private credit, in which the interest has positive elasticity.

The third study evaluates whether the impacts of government and banking efforts during the Covid-19 pandemic would have changed the trend of credit indicators. Through time series models, loan factors such as: balance, payment term, ICC, spread, default rate, and interest rate can be evaluated. In fact, such sharp drops were not expected for ICC, spread, interest rate and especially for the default rate, in which the foreseen scenario was one of stability. The terms were extended and the total balance grew even more. These positive variations can be explained by the outcomes of the Emergency Aid and also by some credit incentive programs launched in the first half of 2020.

Keywords: Credit indicators. Time series. Structural breaks. Demand elasticity. Pandemic.

Lista de ilustrações

Figura 1 – Série temporal do ICC	29
Figura 2 – Série temporal do <i>spread</i>	29
Figura 3 – Série temporal da taxa de juros	30
Figura 4 – Série temporal da inadimplência	30
Figura 5 – ICC: processo de flutuação M generalizado	33
Figura 6 – <i>Spread</i> : processo de flutuação M generalizado	33
Figura 7 – Taxa de juros: processo de flutuação M generalizado	34
Figura 8 – Inadimplência: processo de flutuação M generalizado	34
Figura 9 – Saldo da carteira ativa total x crédito livre x crédito direcionado	46
Figura 10 – Taxa de juros x crédito livre x crédito direcionado	47
Figura 11 – Prazo da carteira ativa total x crédito livre x crédito direcionado	47
Figura 12 – Períodos	52
Figura 13 – Série temporal do saldo total da carteira ativa	71
Figura 14 – Série temporal do prazo médio da carteira	72
Figura 15 – Série temporal do ICC (percentual ao mês)	72
Figura 16 – Série temporal do <i>spread</i>	73
Figura 17 – Série temporal da taxa de juros	73
Figura 18 – Série temporal da inadimplência	74
Figura 19 – Saldo - Previsão período pandemia	76
Figura 20 – Prazo - Previsão período pandemia	77
Figura 21 – ICC - Previsão período pandemia	77
Figura 22 – <i>Spread</i> - Previsão período pandemia	78
Figura 23 – Taxa de juros - Previsão período pandemia	78
Figura 24 – Inadimplência - Previsão período pandemia	79
Figura 25 – Previsões das séries de crédito - 2021	85

Lista de tabelas

Tabela 1 – Decomposição do ICC (em percentual do ICC médio ajustado) .	16
Tabela 2 – Decomposição do ICC (em pontos percentuais)	16
Tabela 3 – Decomposição do <i>Spread</i> do ICC (em proporção do <i>spread</i> . . .	17
Tabela 4 – Decomposição do <i>Spread</i> do ICC (em pontos percentuais) . . .	17
Tabela 5 – Valor dos indicadores em dezembro por ano	31
Tabela 6 – Resultados dos parâmetros e teste de flutuação excessiva	35
Tabela 7 – Elasticidades prazo e juros da demanda de crédito	53
Tabela 8 – Elasticidades cruzadas prazo e juros da demanda de crédito . .	54
Tabela 9 – Valores dos indicadores no período pandemia	70
Tabela 10 – Métricas de Acurácia dos indicadores por modelo	81
Tabela 11 – Saldo: ARIMA(2,2,1)(2,0,0)	82
Tabela 12 – Prazo: ETS(M, Ad,N)	83
Tabela 13 – ICC: ARIMA(3,1,0)(2,0,0)	83
Tabela 14 – <i>Spread</i> : ARIMA(1,1,1)(2,0,0)	83
Tabela 15 – Taxa de juros: ETS(A,A,A)	84
Tabela 16 – Previsões 2021 dos indicadores de crédito	86

Sumário

1	ANÁLISE DE QUEBRAS ESTRUTURAIS DO CUSTO DE CRÉDITO BRASILEIRO	12
1.1	Introdução	12
1.2	Referencial teórico	13
1.2.1	Custo do crédito	13
1.2.2	Estatísticas de mudanças estruturais	18
1.3	Método	22
1.3.1	Processos de flutuação M generalizada	22
1.3.2	Regressão Beta	25
1.4	Dados	27
1.5	Resultados	32
1.6	Discussão	35
1.7	Conclusão	39
2	ELASTICIDADE PRAZO E TAXA DE JUROS SOBRE A DEMANDA DE CRÉDITO LIVRE E DIRECIONADO	41
2.1	Introdução	41
2.2	Referencial teórico	43
2.3	Mercado de crédito livre e direcionado	46
2.4	Método	50
2.5	Dados	50
2.6	Resultados	52
2.7	Discussão	54
2.8	Conclusão	57
3	SÉRIES TEMPORAIS EM INDICADORES DE CRÉDITO - PERÍODO PANDEMIA	59
3.1	Introdução	59
3.2	Referencial Teórico	61

3.2.1	Contexto Econômico pré e durante pandemia - Brasil	61
3.2.2	Séries Temporais em indicadores econômicos - período pandemia . .	62
3.3	Método	63
3.3.1	ARIMA	64
3.3.2	ARIMA com erros <i>XGBoost</i>	65
3.3.3	ETS	66
3.3.4	Regressão linear	67
3.3.5	<i>Prophet</i>	68
3.4	Dados	69
3.5	Resultados	76
3.5.1	Previsões na base teste	76
3.5.2	Métricas de acurácia	80
3.5.3	Parâmetros dos modelos	82
3.5.4	Reajustando para o conjunto de dados completo e previsão 2021 . .	84
3.6	Discussão	86
3.7	Conclusão	89
	 REFERÊNCIAS	 91

1 Análise de quebras estruturais do custo de crédito brasileiro

1.1 Introdução

O crédito tem papel essencial no processo de acumulação de capital, no funcionamento dos setores produtivos e também às famílias. Sem crédito o consumo das pessoas reduz, as empresas produzem menos, o desemprego aumenta e a renda das pessoas cai.

Dentre os principais indicadores de crédito, tem-se o custo do crédito, medido pelo ICC (Indicador do Custo de Crédito). O ICC é definido como o custo de tomar um empréstimo junto a uma Instituição Financeira (IF) e é influenciado, em grande parte, pelo *spread*. O *spread* é a diferença entre o ICC e o custo de captação médio. O custo de captação é o componente de maior peso do ICC e o nível de inadimplência, do *spread* (REB, 2017).

Os dados do custo de crédito brasileiro são atualizados mensalmente no Sistema Gerenciador de Séries Temporais (SGS) pelo Banco Central do Brasil (BCB). O SGS tem acesso livre desde de abril de 2017 e apresenta todos os números relacionados às movimentações bancárias que são enviados ao BCB. Para esse estudo, as séries de tempo analisadas compreendem o ICC, o *spread* do ICC, a taxa de juros dos empréstimos como *proxy* para o custo de captação e a inadimplência da carteira. Todas as variáveis são mensuradas em porcentagem.

Acerca disto, o propósito é trazer um olhar retrospectivo do comportamento das séries que definem o custo do crédito brasileiro, identificando pontos de mudanças no período de janeiro de 2013 a junho de 2021. Nessa quase uma década de análise, o Brasil passou pela crise financeira de 2014, que perdurou até meados de 2017, após, uma estabilidade e retomada econômica, e em março de 2020 até os dias atuais, a pandemia da Covid-19. Será que esses choques econômicos/políticos/sociais teriam causado impactos significantes no custo do crédito? A

hipótese é que sim, existem desvios atípicos nesses momentos.

A metodologia consiste em processos e testes de flutuação M generalizada. Essa técnica foi construída e aperfeiçoada a partir de testes de quebras estruturais bastante conhecidos, como o CUSUM, Nyblom-Hansen, Hjort-Koning, supLM, dentre outros (ZEILEIS, 2006). Testes de flutuação avaliam se os parâmetros de um certo modelo permanecem constantes em todas as observações contra a alternativa de que eles mudam ao longo do tempo.

Dado à natureza percentual dos indicadores do custo do crédito, a estimativa é baseada na regressão beta. Nessa modelagem, a variável dependente tem distribuição beta com um parâmetro de precisão e uma média relacionada a um conjunto de variáveis explicativas por meio de um preditor linear com coeficientes desconhecidos e uma função de ligação (CRIBARI-NETO, 2004); (CRIBARI-NETO; ZEILEIS, 2010). Posteriormente, as funções de estimativas do modelo são plugadas ao cálculo do processo de flutuação. Através da visualização gráfica e teste de instabilidade estrutural, é possível identificar picos de mudança significativos nas séries de tempo — quando os parâmetros do modelo são alterados (BROWN; DURBIN; EVANS, 1975); (DATTA et al., 2020)).

O trabalho se divide em seções. Na primeira seção tem-se o referencial teórico (Seção 1.2), que aborda o custo de crédito e o histórico de estatísticas de quebras estruturais, especialmente, a análise de flutuação M generalizada em regressões beta. Seguidamente, o método é apresentado na Seção 1.3, os dados na Seção 1.4, os resultados na Seção 1.5, a discussão na Seção 1.6 e por fim, a conclusão na Seção 1.7.

1.2 Referencial teórico

1.2.1 Custo do crédito

O custo do crédito reflete a estabilidade do sistema financeiro brasileiro. Este parâmetro é mensurado pelo ICC — índice que mede o custo médio de todas operações de créditos abertas no Sistema Financeiro Nacional (SFN), incorporando tanto contratos novos quanto contratos mais antigos. De acordo com o Relatório

de Economia Bancária (REB) do BCB, a decomposição geral do ICC é agrupada em cinco componentes¹:

1. Custo de captação: despesas das Instituições Financeiras (IF's) com o pagamento de juros nas suas captações;
2. Inadimplência: perdas decorrentes do não pagamento de dívidas;
3. Despesas administrativas: despesas diversas necessárias para realizar operações de crédito;
4. Margem financeira do ICC: parte do ICC que remunera o capital dos acionistas das IF's pelo crédito e outros fatores incluindo erros e omissões nas estimativas;
5. Tributos e Fundo Garantidor de Crédito (FGC): tributos sobre as operações de crédito pagas pelos tomadores e pelas IF's.

O custo de captação captura os custos de captação das concessões de crédito e tem relação com a taxa Selic, já que alguns instrumentos de captação possuem remuneração pré-fixada ou *spreads* fixos em relação à taxa de depósito interbancário (DI). As cadernetas de poupança são uma outra parcela da captação das instituições que são muito sensíveis à taxa Selic quando esta está abaixo de 8,5%, que acontece desde desde 08/09/2017 (REB, 2020).

O nível da inadimplência na economia é um dos mais importantes fatores, pois ele determina o risco da operação de crédito. A inadimplência é definida como o atraso superior a 90 dias em um dado empréstimo. Uma quantidade maior de maus pagadores impacta o custo, uma vez que resulta na necessidade de maiores provisões da IF e aumento na taxa cobrada em algumas operações.

As despesas administrativas refletem o gasto com o pessoal e *marketing*, por exemplo. Nos últimos anos, o crescimento das despesas administrativas tem acompanhado a tendência de variação do Índice Nacional de Preços ao Consumidor Amplo (IPCA), o que reflete o controle dos custos por parte das IF's.

¹ <https://www.bcb.gov.br/content/publicacoes/relatorioeconomiabancaria/reb_2020.pdf>

A margem financeira engloba tanto lucros como outros fatores não mapeados. Em uma simulação feita pelo BCB, embora a participação da margem financeira no ICC seja menor do que das despesas administrativas, a zeragem da margem financeira tem impacto maior no ICC devido ao efeito secundário no valor do componente Tributos e FGC, decorrente da redução da base de cálculo de Imposto de Renda para Pessoas Jurídicas (IRPJ) e Contribuição Social sobre o Lucro Líquido (CSLL) (REB, 2017).

Os tributos e FGC é composto pela contribuição dos clientes, como o Contribuição Social sobre o Lucro Líquido (IOF), e pelas contribuições da IF, como o Programa de Integração Social (PIS), Contribuição para o Financiamento da Seguridade Social (Cofins), Imposto de Renda (IR) e CSLL, além de reterem e recolherem o Imposto de Renda Retido na Fonte (IRRF) incidente sobre os juros sobre capital próprio pagos ou creditados a seus acionistas (REB, 2020).

O índice do *spread* do ICC é dado pela diferença entre o ICC e o custo de captação. Este indicador permite identificar os fatores que determinam o custo do crédito para os tomadores, deixando de fora os efeitos das condições de mercado relacionadas ao custo de captação de recursos, como, por exemplo, o nível da taxa Selic (BROCK; SUAREZ, 2000).

Esses componentes possuem diferentes pesos em relação ao valor final do ICC e do seu *spread*. A metodologia que identifica os fatores e suas contribuições é realizada desde 2017 pelo BCB². Tal decomposição é realizada sobre o ICC médio no ano ajustado, que é calculado por um método de capitalização. Nas Tabelas 1 e 2 são apresentadas as configurações do ICC e do *spread* do ICC para os anos de 2015 a 2020.

² Metodologia de decomposição do custo do crédito e do *spread*, do REB de 2017

Tabela 1 – Decomposição do ICC (em percentual do ICC médio ajustado)

Decomposição	2015	2016	2017	2018	2019	2020
1 - Custo de Captação	40.8	39.7	37.0	35.5	32.7	30.7
2 - Inadimplência	20.8	23.2	24.1	21.8	20.9	21.2
3 - Despesas Administrativas	14.8	14.6	16.0	19.2	19.8	20.2
4 - Tributos e FGC	13.8	13.7	13.9	12.6	16.6	14.0
5 - Margem financeira	9.6	8.6	8.8	10.6	13.6	13.7
ICC médio ajustado	100	100	100	100	100	100

Fonte: REB 2017 e 2020 - Banco Central do Brasil.

Tabela 2 – Decomposição do ICC (em pontos percentuais)

Decomposição	2015	2016	2017	2018	2019	2020
1 - Custo de Captação	7.72	8.15	7.50	6.82	6.28	5.24
2 - Inadimplência	3.94	4.77	4.88	4.19	4.01	3.62
3 - Despesas Administrativas	2.81	3.00	3.26	3.69	3.81	3.46
4 - Tributos e FGC	2.61	2.82	2.82	2.42	2.43	2.40
5 - Margem financeira	1.82	1.78	1.79	2.05	2.62	2.35
ICC médio ajustado	18.91	20.52	20.26	19.17	19.16	17.07

Fonte: REB 2017 e 2020 - Banco Central do Brasil.

A maior parte da decomposição do ICC se refere ao custo de captação (Tabela 1). No período analisado, observa-se que a contribuição do custo de captação reduziu, a contribuição das despesas administrativas e da margem financeira aumentou e a contribuição da inadimplência e dos tributos e FGC se manteve estável.

Considerando a média do período 2015-2017, o custo de captação contribuiu com 39% na decomposição do ICC, a inadimplência com 22%, as despesas administrativas com 15%, os tributos e FGC com 13% e, finalmente, a margem financeira com 9%. Considerando a média do período 2018-2020, o custo de captação contribuiu com 33% na decomposição do ICC, a inadimplência com 21%, as despesas administrativas com 19.8%, os tributos e FGC com 13% e, finalmente, a margem financeira com 12%.

Avaliando a Tabela 2, de 2015 a 2017, nota-se que o ICC aumentou em 2016 (20.5%) e reduziu em 2017 (20.2%), influenciado, em grande parte, pelo comportamento do custo de captação. A inadimplência e as despesas administrativas tiveram crescimentos contínuos nesse período. Os tributos e FGC aumentaram em 2016 e se mantiveram em 2017. E a margem financeira não apresentou grandes variações. Olhando para 2020, o ICC apresentou uma redução de 2.1 p.p. em relação a 2019 e é o menor valor observado (17.07%) dentre os anos analisados. O principal componente contribuinte para a queda do ICC foi o custo de captação (-1.04 p.p.), seguido da inadimplência (-0.39 p.p.), despesas administrativas (-0.35 p.p.), margem financeira (-0.27 p.p.) e, por último, tributos e FGC (-0.03 p.p.).

Agora, ao considerar a configuração do *spread* do ICC (Tabela 4), as contribuições em pontos percentuais dos componentes são as mesmas que as reportadas para a decomposição do ICC. Todavia, as participações percentuais destes se ampliam em virtude da exclusão do custo de captação (Tabela 3).

Tabela 3 – Decomposição do *Spread* do ICC (em proporção do *spread*)

Decomposição	2015	2016	2017	2018	2019	2020
1 - Inadimplência	35.2	38.5	38.2	33.9	31.1	30.6
2 - Despesas Administrativas	25.1	24.2	25.5	29.8	29.6	29.2
3 - Tributos e FGC	23.3	22.7	22.1	19.6	18.8	20.2
4 - Margem financeira	16.2	14.4	14.0	16.6	20.3	19.8
<i>Spread</i> do ICC	100	100	100	100	100	100

Fonte: REB 2017 e 2020 - Banco Central do Brasil.

Tabela 4 – Decomposição do *Spread* do ICC (em pontos percentuais)

Decomposição	2015	2016	2017	2018	2019	2020
1 - Inadimplência	3.94	4.77	4.88	4.19	4.01	3.62
2 - Despesas Administrativas	2.81	3.00	3.26	3.69	3.81	3.46
3 - Tributos e FGC	2.61	2.82	2.82	2.42	2.43	2.40
4 - Margem financeira	1.82	1.78	1.79	2.05	2.62	2.35
<i>Spread</i> do ICC	11.19	12.37	12.76	12.35	12.81	11.83

Fonte: REB 2017 e 2020 - Banco Central do Brasil.

Analisando as contribuições médias entre 2015 e 2017 da Tabela 3, a inadimplência respondeu por 37%, seguido por despesas administrativas (24%), tributos e FGC (22%) e, logo após, a margem financeira do ICC (14%). Considerando os valores médios entre 2018 e 2020, a inadimplência respondeu por 31.9%, seguido por despesas administrativas (29.6%), tributos e FGC (19.6%) e, logo após, a margem financeira do ICC (18.9%). O *spread* do ICC tem seu maior valor em 2019 (12.81%) e o menor em 2015 (11.19%).

1.2.2 Estatísticas de mudanças estruturais

A primeira estatística para teste de quebra estrutural foi proposta por **CHOW** na década de 60. Basicamente, o teste de Chow consiste na estimação por mínimos quadrados de duas subamostras geradas a partir de um ponto de quebra conhecido, caso forneça um ajuste melhor do que estimar a amostra inteira de uma vez, a quebra é significativa. Simultaneamente, **QUANDT** introduziu uma estatística de teste de razão de verossimilhança para ponto de mudança desconhecido que testa a hipótese alternativa de mudanças na variância do erro.

Porém, a partir do trabalho de **BROWN; DURBIN; EVANS**, testes de flutuação para mudança estrutural são explorados. Testes de flutuação avaliam se os parâmetros de um certo modelo permanecem constantes em todas as observações contra a alternativa de que eles mudam ao longo do tempo. A proposta apresentada consiste em técnicas de análise de resíduos recursivos por meio do teste CUSUM para avaliar a significância de uma única quebra estrutural na série de tempo.

Um outro teste bastante conhecido e base de muitos outros posteriores é a estatística de Nyblom-Hansen. Aqui, hipótese nula é que os parâmetros não se alteram ao longo do tempo contra a alternativa de que alguns deles são instáveis (**NYBLOM, 1989**). E o teste de Hansen, baseado no teste de Nyblom, avalia a especificação correta dos problemas da verossimilhança através de uma possível instabilidade no parâmetro que permite dependência em relação ao tempo (**HANSEN, 1992**). Posteriormente, **HJORT; KONING** usam uma abordagem fundamentada em pontuações de máxima verossimilhança, considerada uma extensão do teste de Nyblom-Hansen. A metodologia se aplica a modelos paramétricos regulares, como regressão e cadeia de Markov.

PLOBERGER; KRÄMER propuseram o teste de flutuação baseado na soma acumulada dos resíduos OLS (CUSUM-OLS) ao invés de resíduos recursivos. A estimação de parâmetros foi realizada em um modelo de regressão linear dinâmico para mostrar a mudança estrutural e pode ser aplicado a dados de tendência (PLOBERGER; KRÄMER, 1996).

ANDREWS considerou testes de instabilidade de parâmetro e quebra estrutural única com ponto de mudança desconhecido através de estatísticas F: *Lagrange Multiplier* (LM), *Wald, Likelihood Ratio* (LR) — nominados testes de supF. Os testes apresentaram bom desempenho. Seguidamente, ANDREWS; DOAN; PLOBERGER desenvolveram os testes *Exponential* (exp) e *Average* (ave). Enquanto o teste sup encontra o ponto de quebra mais possível que maximiza as estatísticas do Chow, os testes ave e exp usam todos os valores das estatísticas do Chow e são apenas informativos sobre a existência do intervalo, mas não sua data.

CHU; HORNIK; KUAN e CHU; HORNIK; KUAN introduziram os testes MOSUM, baseados em somas móveis dos resíduos recursivos ou resíduos OLS de um modelo de regressão linear.

Porém, a estrutura de testes de flutuação generalizada foi proposta por KUAN; HORNIK e, mais adiante, estendida para modelos paramétricos gerais determinados com estimadores do tipo M (ZEILEIS; HORNIK, 2003). Dessa forma, muitas das abordagens citadas são casos especiais da classe de testes de flutuação M generalizada, como os testes CUSUM e MOSUM baseados em resíduos OLS (PLOBERGER; KRÄMER, 1992); (PLOBERGER; KRÄMER, 1996); (CHU; HORNIK; KUAN, 1995a); o teste de Nyblom-Hansen (NYBLOM, 1989); (HANSEN, 1992); a classe de testes fundamentada em *scores* de máxima verossimilhança (HJORT; KONING, 2002); e os testes de supF, aveF e expF usando estatísticas LM (única baseada na estimativa de amostra completa) (ANDREWS, 1993); (ANDREWS; DOAN; PLOBERGER, 1994).

Os testes de M flutuações são construídos escolhendo primeiro uma técnica de estimativa apropriada, segundo, derivando um processo de soma parcial das pontuações de estimativa que captura instabilidades ao longo do tempo, e, terceiro, agregando esse processo a uma estatística de teste usando um funcional escalar.

A inferência é baseada em teoremas de limite central funcional que são derivados sob a hipótese nula de estabilidade de parâmetro. Os casos especiais relatados se diferem quanto a funcional empregada para capturar as flutuações excessivas (ZEILEIS, 2005).

Embora originalmente implementado para modelos de regressão linear (ZEILEIS et al., 2002), ZEILEIS estendeu a análise de flutuação M generalizada para mudança estrutural em modelos que são baseados em funções de estimativa adequadas. O uso do modelo de regressão beta para dados que variam entre 0 e 1 é uma das possibilidades (CRIBARI-NETO; ZEILEIS, 2010). O cálculo do processo de flutuação M com base na regressão é beta é como apresentada em ZEILEIS. O modelo é ajustado via máxima verossimilhança e as funções de estimativa avaliadas em dados observados e parâmetros estimados são extraídas por meio de uma função dada em CRIBARI-NETO.

Na prática, as estatísticas de mudanças estruturais podem ser reconhecidas no campo da economia, nas políticas e na análise de dados — particularmente na econometria de séries temporais (NELSON; PLOSSER, 1982); (JUSHAN; PERRON, 1998); (CHATURVEDI; KUMAR, 2007); (BAI, 2010); (TZAVALIS; MELIGKOTSIDOU; VRONTOS, 2011); (AGIWAL; KUMAR; SHANGODOYIN, 2018). Para saber se, quando e como o mecanismo de dados a um conjunto de observações muda, estes artigos exploram o estudo de testes, estimativas e detecção de quebras estruturais únicas ou múltiplas de séries univariadas ou multivariadas em diversos conjuntos de dados do mundo real.

NELSON; PLOSSER investigam se séries macroeconômicas têm tendência ou diferença estacionária. Na maioria das séries, a hipótese de raiz unitária (séries não estacionárias) não é rejeitada, com exceção da taxa de desemprego. Nesses casos, a série é caracterizada por um passeio aleatório que não retorna ao seu caminho anterior após uma perturbação aleatória. Seu nível muda permanentemente e o choque tem um efeito permanente.

Sob perspectiva bayesiana, as condições iniciais desconhecidas são tratadas como variáveis aleatórias, apropriadas em testes de séries raiz unitária. Em CHATURVEDI; KUMAR, a presença de raízes unitárias é testada por meio de

modelos com diversos pontos de interrupção únicos conhecidos e desconhecidos. Observa-se que ignorar a presença de quebras estruturais no modelo pode levar à conclusão equivocada de aceitação da hipótese nula. TZAVALIS; MELIGKOTSIDOU; VRONTOS comparam modelos de raiz unitária com modelos estacionários quando o nível e a variância do erro estão sujeitos a mudanças estruturais em uma data desconhecida. AGIWAL; KUMAR; SHANGODOYIN exploram o efeito de múltiplas quebras presentes na média e na variância do erro ao mesmo tempo. Estimativas de *bayes* são obtidas para diferentes funções de perda usando distribuição condicional posterior. Para o teste de hipótese, o *odds ratio* posterior é calculado e resolvido por meio da Integração de Monte Carlo. A metodologia proposta é ilustrada com exemplos numéricos.

Com foco em aplicações recentes na economia, a análise de mudanças estruturais é explorada em temas como, mercado de crédito, crises econômicas, a recente pandemia da COVID-19, criptografia, macroeconomia e finanças. O objetivo é encontrar choques significantes nas séries temporais, avaliar os porquês e realizar estimativas mais precisas.

O estudo de XING et al. avalia a transição de classificação das empresas dos EUA de janeiro de 1986 a fevereiro de 2017 como uma *proxy* do mercado de crédito. Grandes pontos de mudanças nas transições de classificação das empresas podem ser capturados. Também é sugerido regras de monitoramento da estabilidade financeira para detectar quebras estruturais.

Em DATTA et al. é analisado o padrão de mudança dos casos de Covid-19. Os pontos de interrupção são identificados por meio de metodologia estatística e, em seguida, examinam-se a tendência de mudança em cada intervalo de quebra. Os autores analisam cada estágio separadamente para entender o comportamento da transmissão do vírus.

Uma aplicação de testes de múltiplas quebras estruturais em mercados de criptografia é realizada por TELLI; CHEN. Por meio destes, detectam padrões de mudanças de tendência das diversas séries de retorno e volatilidade de ativos da *Bitcoin*.

STÜBINGER; ADLER desenvolvem um algoritmo para encontrar sequen-

cias semelhantes mas com deslocamento de fases, onde quebras estruturais também são capturadas. Aplicado a dados de finanças e macroeconomia, os autores identificam padrões de regime (eventos econômicos e políticos) ao longo do tempo.

Em [CAPPELLI et al.](#) utiliza-se uma estrutura denotada *Atheoretical Regression Trees* para detectar mudanças estruturais em séries diárias dos preços das ações, onde os valores no tempo são dispostos em intervalos — os limites são definidos por meio dos preços de fechamento. Os resultados e o método são validados por meio de experimentos empíricos.

[SHAHBAZ; HAOUAS; SOHAG](#) aplicam teste de quebra estrutural e cointegração para avaliar a ligação entre desenvolvimento financeiro e a degradação ambiental. Incorpora-se variáveis de crescimento econômico, consumo de eletricidade e globalização econômica na função de emissões de CO₂ nos Emirados Árabes Unidos de 1975 a 2014. As relações causais são avaliadas por meio do teste de causalidade de Toda-Yamamoto. Os resultados sugerem que o desenvolvimento financeiro (globalização) aumenta as emissões de CO₂ e é positivamente relacionado à degradação ambiental.

1.3 Método

1.3.1 Processos de flutuação M generalizada

Em estudos de mudanças estruturais, o objetivo é avaliar se os parâmetros de um determinado modelo permanecem constantes ou se mudam ao longo do tempo. Dado um modelo paramétrico com parâmetro θ k -dimensional para n observações ordenadas de uma variável vetorial $Y_i (i = 1, \dots, n)$ e supondo que para cada observação no tempo i existe um θ de modo que o modelo se mantenha, as hipóteses são dadas por:

$$\begin{aligned} H_0 : \theta_i &= \theta_0 \quad (i = 1, \dots, n) \\ H_A : \theta_i &\text{ muda ao longo do tempo } i. \end{aligned} \tag{1.1}$$

A metodologia de flutuação generalizada consiste em estimar o vetor de parâmetros para todas as n observações baseadas em uma função de pontuação

de M estimativa $\psi(\cdot)$. Posteriormente, usar o processo de soma cumulativa dessas pontuações para detectar instabilidades nos parâmetros. O estimador M é definido por (ZEILEIS, 2006):

$$\sum_{i=1}^n \psi(Y_i, \hat{\theta}) = 0. \quad (1.2)$$

Sob a estabilidade do parâmetro, as pontuações $\psi(Y_i, \hat{\theta})$ têm média zero, mas sob a alternativa, haverá desvios sistemáticos de zero que podem ser capturados usando o processo de soma cumulativa das pontuações:

$$W_n(t) = n^{1/2} \sum_{i=1}^{\lfloor nt \rfloor} \psi(Y_i, \hat{\theta}). \quad (1.3)$$

É mostrado que para este processo o teorema do limite central funcional (*Functional Central Limit Theorems* - FCLT) é válido. Isto implica que $W(\cdot)$ converge para $Z(\cdot)$, que é um processo gaussiano com média zero e função de covariância $\text{COV}[Z(t), Z(s)] = \min(t, s) \cdot J$. Nessa equação, J é a matriz de covariância (assintótica) das pontuações ψ (HJORT; KONING, 2002); (ZEILEIS, 2005). O estimador para esta estrutura de covariância é definido como:

$$\hat{J} = n^{-1} \sum_{i=1}^n \psi(Y_i, \hat{\theta}) \psi(Y_i, \hat{\theta})^T. \quad (1.4)$$

Dada a estimativa da matriz de covariância \hat{J} , o processo de flutuação empírico $\text{efp}(\cdot)$ para cada componente j pode ser calculado por meio da função:

$$\text{efp}_j(t) = \hat{J}^{-1/2} W_n(t), \quad (1.5)$$

que converge para uma ponte browniana k -dimensional, $\text{efp}_j(\cdot) \xrightarrow{d} W^0(\cdot)$, onde $W^0(t) = W(t) - tW(1)$ (HJORT; KONING, 2002).

Este FCLT fornece a base probabilística para calcular a distribuição limite para os testes de significância, que serão descritos a seguir.

Com a derivação do processo de flutuação empírica (Equação 1.5), já é possível averiguar visualmente as flutuações que capturam as instabilidades nas estimativas dos parâmetros. Mas, para inferência dos desvios a um certo limite, o processo deve ser agregado a uma estatística de teste usando algum funcional escalar λ .

Em amostras finitas, o processo é essencialmente uma matriz $(\text{efp}_j(i/n))_{i,j}$ com $i = 1, \dots, n$ correspondente a pontos do tempo e $j = 1, \dots, k$ correspondente aos componentes do vetor de parâmetro θ . Duas estratégias para a construção de uma estatística de teste são possíveis: 1. Agregar o processo ao longo do tempo primeiro, produzindo k estatísticas de teste independentes a cada componente; 2. Primeiro agregar sobre os componentes, resultando em um processo de flutuação que pode revelar o tempo de uma mudança estrutural. Dessa forma, λ pode ser dividida em duas partes: λ_{tempo} e λ_{comp} para agregação ao longo do tempo e componentes, respectivamente. As opções típicas para o tempo de λ_{tempo} são o máximo absoluto L_∞ , a média ou o intervalo e para λ_{comp} , L_∞ ou a norma euclidiana quadrada L_2 (mais exemplos em [HJORT; KONING](#)).

A funcional que permite ambas as interpretações é a estatística dupla máxima:

$$\max_{i=1, \dots, n} \max_{j=1, \dots, k} \left| \frac{\text{efp}_j(i/n)}{b(i/n)} \right|, \quad (1.6)$$

onde L_∞ é usado para agregação em ambas as direções e a hipótese nula de estabilidade é rejeitada quando o máximo excede alguma função de limite $b(t)$, geralmente, $b(t) = 1$.

Por outro lado, quando há evidências de uma mudança estrutural, uma pergunta muito natural é quando ela ocorreu. Para focar nesta questão, é melhor primeiro agregar sobre os componentes, visualizar o processo univariado resultante quanto à flutuação excessiva e assim, verificar se este cruza algum limite de significância ([ZEILEIS et al., 2003](#)). A estatística de Cram'ervon Mises ([NYBLÖM, 1989](#)); ([HANSEN, 1992](#)) é um teste poderoso e permite a inspeção visual do processo $\text{efp}(t)$, que pode transmitir informações sobre o tempo de uma potencial mudança estrutural ([HJORT; KONING, 2002](#)). Em sua construção, primeiro se

agrega os componentes usando a norma euclidiana quadrada L_2 e, em seguida, ao longo do tempo, toma-se a média:

$$n^{-1} \sum_{i=1}^n \|\text{efp}(i/n)\|_2^2. \quad (1.7)$$

Em resumo, o teste de flutuação M generalizada é construído a partir das seguintes etapas: 1. Estimar o modelo que deve ser testado para instabilidades estruturais; 2. Derivar um processo de flutuação empírica das somas cumulativas de M pontuações de estimativa que são governadas por um FCLT e que captura flutuações ao longo do tempo; 3. Agregar o processo de flutuação empírica a uma estatística de teste, complementada por uma técnica de visualização que fornece fronteiras de desvio para os parâmetros com uma probabilidade conhecida α (ZEILEIS; HORNIK, 2003); (ZEILEIS, 2006).

1.3.2 Regressão Beta

Dado à natureza percentual dos dados do custo de crédito, um pequeno ajuste é necessário. A distribuição beta é muito flexível para modelar séries restritas ao intervalo da unidade padrão (0,1), pois sua densidade pode ter formas bastante diferentes dependendo dos valores dos dois parâmetros que indexam a distribuição (FERRARI; CRIBARI-NETO, 2004). Além disso, acomoda heteroscedasticidade e assimetria dos dados.

A densidade beta é dada por:

$$f(y; p, q) = \frac{\Gamma(p+q)}{\Gamma(p)\Gamma(q)} y^{p-1} (1-y)^{q-1}, \quad 0 < y < 1, \quad (1.8)$$

onde $p, q > 0$ e $\Gamma(\cdot)$ é a função gamma $\Gamma(p) = \int_0^\infty y^{p-1} e^{-y} dy$. A média é a variância são, respectivamente:

$$\begin{aligned} E(y) &= \frac{p}{(p+q)}, \\ \text{var}(y) &= \frac{pq}{(p+q)^2(p+q+1)}. \end{aligned} \quad (1.9)$$

CRIBARI-NETO propôs uma reparametrização da densidade beta, onde $\mu = p/(p+q)$ e $\phi = p+q$, ou seja, $p = \mu\phi$ e $q = (1-\mu)\phi$, que permite a modelagem da média da resposta envolvendo o parâmetro de precisão. Essa estrutura consiste em:

$$f(y; \mu, \phi) = \frac{\Gamma(\phi)}{\Gamma(\mu\phi)\Gamma((1-\mu)\phi)} y^{\mu\phi-1} (1-y)^{(1-\mu)\phi-1}, \quad (1.10)$$

onde $0 < y < 1, 0 < \mu < 1, \phi > 0$. Denota-se que $y \sim B(\mu, \phi)$. Aqui, ϕ é o parâmetro de precisão, e para μ fixo, quanto maior ϕ , menor é a variância de y . A complementar, a média e a variância são definidas como:

$$\begin{aligned} E(y) &= \mu, \\ var(y) &= \frac{\mu(1-\mu)}{1+\phi}. \end{aligned} \quad (1.11)$$

Para a construção do modelo, considere y_1, \dots, y_n variáveis aleatórias independentes, em que cada $y_i, i = 1, \dots, n$, tem densidade na forma da Equação 1.10 com média μ_i e precisão ϕ desconhecido. O modelo de regressão beta com precisão fixa assume que a média satisfaz a seguinte relação funcional:

$$g(\mu_i) = \sum_{j=1}^k x_{ij} \beta_j = \eta_i, \quad (1.12)$$

em que $\beta = (\beta_1, \dots, \beta_k)^\top$ é o vetor de parâmetros desconhecidos e x_{i1}, \dots, x_{ik} são observações de k variáveis independentes (covariáveis) conhecidas ($k < n$). De acordo com esse modelo, $\mu_t = g^{-1}(\eta_t)$ e $var(y_t) = V(g^{-1}(\eta_t))/(1+\phi)$, e mesmo que o parâmetro de precisão seja constante para todas as observações as variâncias não são constantes, uma vez que a variância da resposta depende de μ (Equação 1.11). Por fim, $g(\cdot)$ é uma função de ligação com domínio $(0, 1)$. Neste estudo aplica-se a especificação logito $g(\mu) = \log(\mu/(1-\mu))$.

Para estimar os parâmetros do modelo, utiliza-se a função de log-verossimilhança dos parâmetros $\theta = (\beta^T, \phi)^\top$, que é baseada na Equação 1.10 (PAOLINO, 2001):

$$\begin{aligned}\ell(\beta, \phi) &= \sum_{i=1}^n \ell_i(\mu_i, \phi), \quad \text{onde:} \\ \ell_i(\mu_i, \phi) &= \log \Gamma(\phi) - \log \Gamma(\mu_i \phi) - \log \Gamma((1 - \mu_i) \phi) \\ &\quad + (\mu_i \phi - 1) \log y_i + ((1 - \mu_i) \phi - 1) \log(1 - y_i).\end{aligned}\tag{1.13}$$

A estimativa dos parâmetros β e ϕ é realizada por máxima verossimilhança (CRIBARI-NETO, 2004); (CRIBARI-NETO; ZEILEIS, 2010). Como não possuem forma fechada, os estimadores podem ser obtidos numericamente através de algoritmos como o *Newton-Raphson*, *Escore de Fisher*, BFGS. Neste trabalho, o algoritmo utilizado é o BFGS (*Broyden-Fletcher-Goldfarb-Shanno*) (BYRD et al., 1995).

Como dito anteriormente, as funções de estimativas encontradas nas séries de crédito são extraídas por meio de uma função elaborada por CRIBARI-NETO. Através do pacote **betareg** do R pode-se plugar em várias funções de inferência, e uma delas é o teste de flutuação M generalizada (CRIBARI-NETO; ZEILEIS, 2010).

1.4 Dados

O SGS³ disponibilizado pelo BCB apresenta valores mensais dos indicadores de crédito das operações do SFN e suas respectivas notas metodológicas.

Com foco em estudar o custo do crédito no Brasil, analisam-se o ICC e seus componentes principais: *spread*, inadimplência e taxa de juros. As séries compreendem o período de janeiro de 2013 a junho de 2021. Suas definições formais são dadas através do Glossário de Crédito do BCB:⁴

1. Indicador de Custo de Crédito (ICC): custo médio das operações de crédito que integram a carteira de empréstimos, financiamentos e arrendamento mercantil das IF's integrantes do SFN. Inclui todas as operações em aberto

³ <<https://www3.bcb.gov.br/sgspub/localizarseries/localizarSeries.do?method=prepararTelaLocalizarSeries>>

⁴ <https://www.bcb.gov.br/content/estatisticas/docs_estatisticasmonetariascredito/glossariocredito.pdf>

classificadas no ativo circulante, independente da data de contratação do crédito;

2. *Spread* médio do ICC: refere-se à diferença entre a taxa média de juros e o custo de captação estimado, compreendendo o lucro e o risco relativos às operações de crédito;
3. Taxa média de juros: percentual cobrado pelas IF's nas operações de crédito realizadas com seus clientes, ou seja, a média das taxas de juros das concessões ponderada pelos respectivos valores desembolsados.
4. Inadimplência da carteira: relação percentual do somatório do saldo das operações de crédito com atraso acima de 90 dias e não baixado para prejuízo, dividido pelo saldo total da carteira de crédito.

As Figuras 1, 2, 3 e 4 demonstram o comportamento dos indicadores analisados de 2013 até junho de 2021. O ICC e a taxa média de juros são medidos em percentual ao ano, o *spread* do ICC em pontos percentuais (expressa o valor absoluto da diferença entre o percentual do ICC e o percentual do custo de captação) e a inadimplência tem natureza percentual das operações em atraso de um certo mês. A linha em azul representa uma curva “suave”, que aumenta ou diminui monotonicamente ao longo da série temporal. Essa curva tem comportamento muito similar nos indicadores, iniciam-se em 2013 em um patamar baixo, aumentam no meio da série e apresentam queda nos últimos anos.

A série do ICC tem seu maior valor em fevereiro de 2017 com 22.98% a.a. e o menor em dezembro de 2020 com 16.76% a.a.. O *spread* tem 14.74 p.p. em outubro de 2019 e 11.47 p.p. em dezembro de 2013. Para a taxa de juros, o pico de alta é atingido em agosto de 2016 com 2.39% a.m. (também encontrado em setembro e novembro do mesmo ano) e o pico de queda em setembro de 2020 com 1.39% a.m.. E por fim, no caso da inadimplência da carteira, o maior valor (4.04%) ocorreu em maio de 2017 e o menor (2.12%) em dezembro de 2020.

Figura 1 – Série temporal do ICC




Figura 2 – Série temporal do spread




Figura 3 – Série temporal da taxa de juros

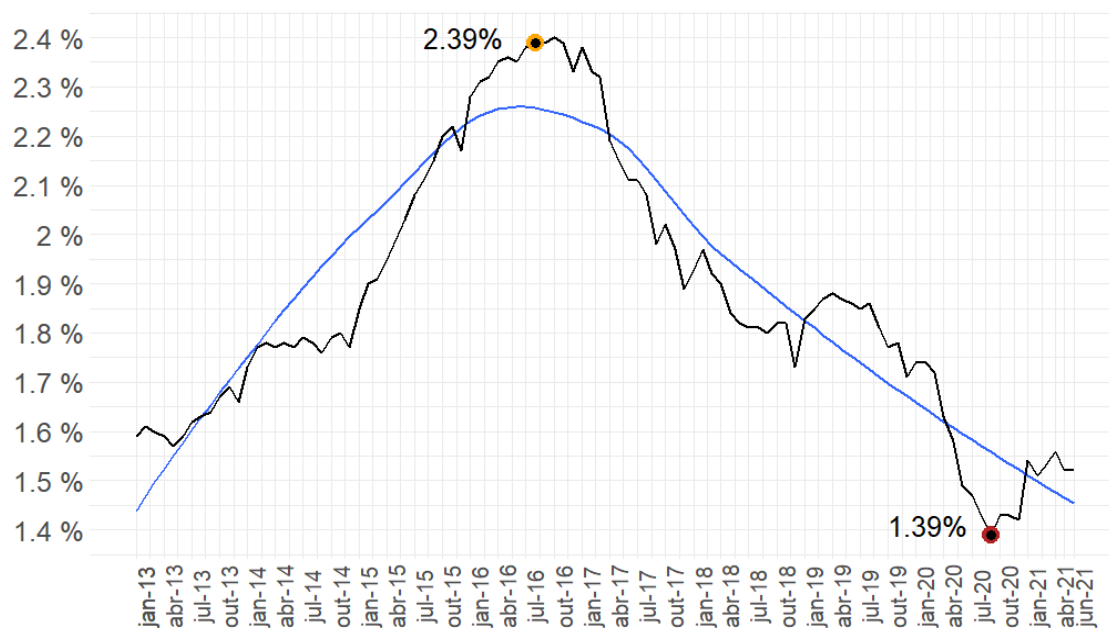



Figura 4 – Série temporal da inadimplência



A Tabela 5 apresenta os valores dos indicadores no final de cada ano avaliado.

Tabela 5 – Valor dos indicadores em dezembro por ano

Ano	ICC (% a.a.)	<i>Spread</i> (p.p.)	Taxa de juros (% a.m.)	Inadimplência (%)
2013	18.72	11.47	1.66	2.86
2014	19.12	11.50	1.77	2.73
2015	21.15	12.70	2.17	3.37
2016	22.56	14.11	2.33	3.70
2017	21.16	13.84	1.89	3.24
2018	20.36	13.52	1.73	2.87
2019	20.27	14.38	1.71	2.93
2020	16.76	11.81	1.42	2.12
06/2021	17.31	12.16	1.52	2.30

- 2013: o ICC se inicia em 18.7% a.a., o *spread* em 11.4 p.p., a taxa de juros em 1.66% a.m. e a inadimplência em 2.86%;
- 2014: a elevação das taxas de juros foi acompanhada pela ampliação dos *spreads*. O comprometimento de renda das famílias com o serviço das dívidas bancárias manteve-se relativamente estável;
- 2015 e 2016: crescimento ininterrupto de todos os indicadores refletindo os efeitos da recessão econômica no Brasil;
- 2017: aqui, observa-se finalmente, o início da redução do custo do crédito brasileiro. O ICC tem valor de 21.1% a.a., o *spread* 13.8 p.p., a taxa de juros 1.8% a.m. e a inadimplência 3.2%;
- 2018: a taxa de juros diminui 4.6 p.p. em relação a 2017, influenciada pela redução e manutenção dos níveis da taxa básica de juros, bem como pelo decréscimo da inadimplência;
- 2019: com exceção da inadimplência, todos os indicadores apresentam redução em relação a 2018;
- 2020: os indicadores possuem o menor percentual de todo o período analisado — ano da pandemia da Covid-19;

- 2021: em junho deste ano, há um aumento para todos os componentes do custo do crédito. O ICC passa de 16.6 para 17.3% a.a., o *spread* de 11.8 para 12.1 p.p., a taxa de juros de 1.4 para 1.5% a.m. e a inadimplência de 2.1 para 2.3%.

1.5 Resultados

Para a análise de quebras estruturais em cada série dos indicadores de crédito, ajusta-se o modelo de regressão beta sem regressores, ou seja, somente o intercepto é considerado, logo $x_{i1} = 1$, para $i = 1, \dots, n$ (Equação 1.12). Como explicado anteriormente, as estimativas do modelo são extraídas e plugadas ao ajuste da estrutura efp.

Posteriormente, um processo de flutuação M generalizado é estimado e a inferência é obtida por meio da estatística de Cram'ervon Mises (Equação 1.7). Essa técnica é projetada para revelar as instabilidades de uma forma gráfica, e portanto, as Figuras 5, 6, 7 e 8 apresentam duas linhas horizontais, uma para a média empírica e outra para o valor crítico — visualização tanto do teste de significância quanto da flutuação excessiva. Se os parâmetros forem estáveis, o processo de soma cumulativa deve flutuar aleatoriamente em torno de zero. No entanto, se houver uma mudança abrupta nos parâmetros, as somas cumulativas se desviarão claramente de zero e terão um pico próximo ao momento da mudança.

Os desvios são significantes e deve-se rejeitar a hipótese nula (Equação 1.1) quando o processo de flutuação empírica cruza os limites dado em linha vermelha (valor crítico de 5%).

Figura 5 – ICC: processo de flutuação M generalizado

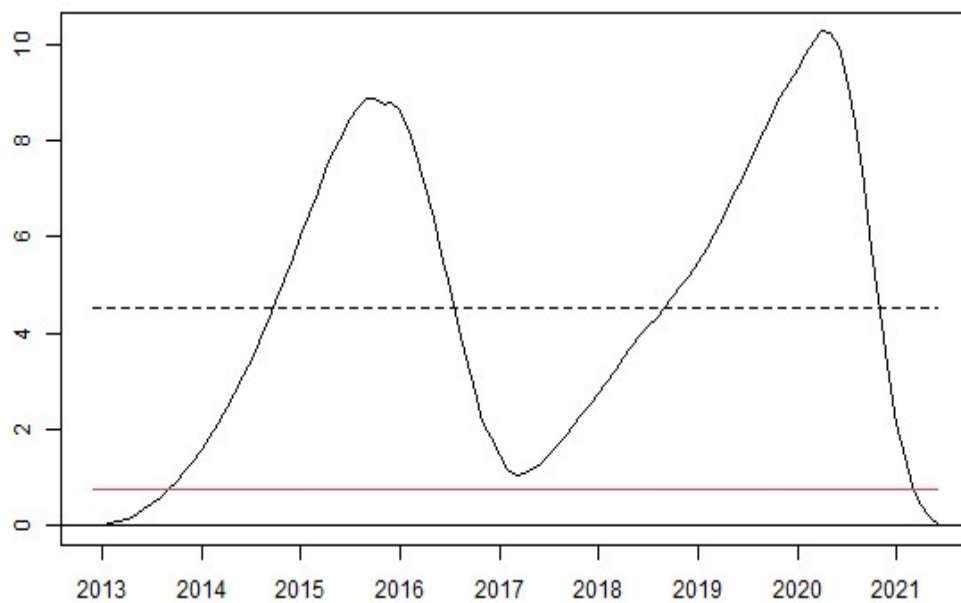


Figura 6 – Spread: processo de flutuação M generalizado

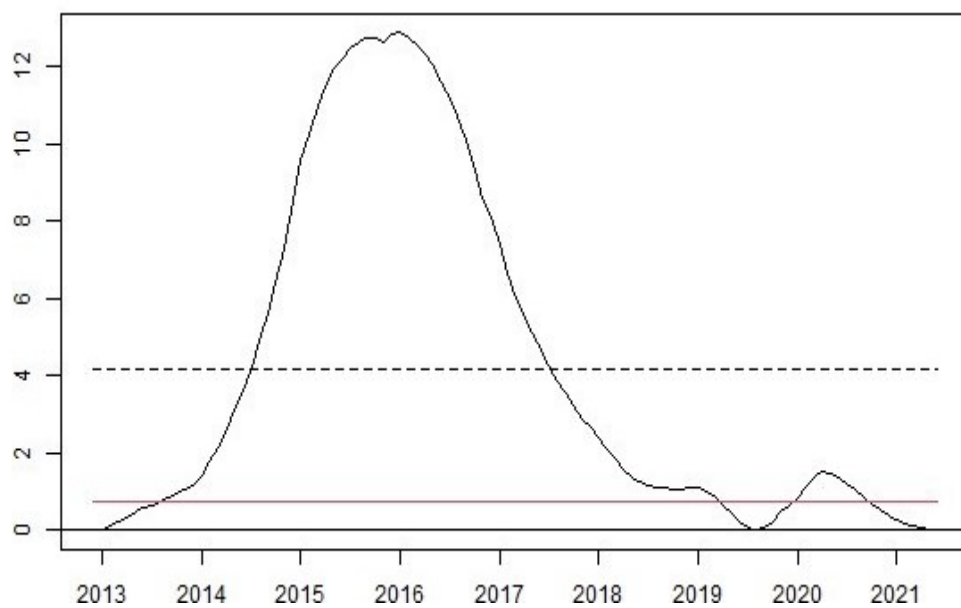


Figura 7 – Taxa de juros: processo de flutuação M generalizado





Figura 8 – Inadimplência: processo de flutuação M generalizado



A Figura 5 do ICC aponta dois picos: o primeiro no período entre 2015 e 2016 e um outro ainda mais evidente no ano de 2020. No caso do *spread* (Figura

6, a flutuação significativa ocorre em 2016. Para a taxa de juros (Figura 7), o pico ocorrido em 2020 sugere que ocorreu uma mudança na média aproximadamente nesse período, comportamento muito similar à inadimplência (Figura 8). Os parâmetros estimados e as estatísticas do teste de instabilidade nos parâmetros são apresentados a seguir.

Tabela 6 – Resultados dos parâmetros e teste de flutuação excessiva

Indicadores	Parâmetros		Teste de M flutuação	
	Intercepto	ϕ	$f(\text{efp})$	p-valor
ICC	-1.36	631.4	4.21	0.005
Spread	-1.88	1,022	4.16	0.005
Taxa de juros	-3.96	2,506	3.72	0.005
Inadimplência	-3.43	1,602	3.95	0.005

Os parâmetros ajustados, intercepto e ϕ , do modelo de regressão beta são relevantes para todos os indicadores de crédito. Pela Tabela 6, nota-se que os testes de flutuação M generalizada apresentam um valor de p assintótico altamente significativo aproximado de 0.005 (o menor valor de p armazenado nessa estrutura). Ou seja, os parâmetros se alteram ao longo do tempo e as quebras estruturais apontadas são estatisticamente significativas.

1.6 Discussão

Tanto o ICC quanto o *spread* apresentaram flutuações excessivas, ou quebras estruturais, durante os anos 2015/2016. O ICC chegou a quase 23% a.a. e o *spread* a 14.5 p.p. em 2016 (Tabelas 1 e 2). A taxa de juros e a inadimplência das operações de crédito chegaram aos maiores níveis dentre os anos analisados, 2.39% a.m. e 4.04%, mas ambas não apresentaram picos de mudança significativas nesse período e sim em outro momento.

Uma explicação para o aumento dos indicadores do custo do crédito é que, entre 2014 e 2016 a economia brasileira passou por uma profunda recessão — os recuos foram de 3.5% do PIB, tanto para 2015 como para 2016. A desaceleração econômica provocou a redução da demanda por crédito, desencadeando um ciclo

vicioso, em razão das condições mais restritivas para a concessão de crédito e do aumento dos custos envolvidos nessas operações. O aumento das taxas de juros dos empréstimos foi impulsionado pelo movimento da recomposição dos *spreads*. Essa recomposição dos *spreads* decorreu tanto do maior risco percebido da inadimplência, diante do aumento do endividamento e do grau de comprometimento dos rendimentos das famílias e das empresas, mas também do aumento do “custo de oportunidade” dessas operações (OLIVEIRA; WOLF, 2016).

A inadimplência afeta as taxas de juros cobradas nos empréstimos em dois aspectos primordiais: a sua prevalência (em outras palavras, quantos clientes deixam de pagar) e o prazo das operações. Quanto maior a taxa de inadimplência, maior a taxa de juros necessária para cobrir a perda com a inadimplência. Quanto maior o prazo das operações de crédito, menor a taxa de juros necessária para cobrir a perda com a inadimplência. O nível da inadimplência depende de uma série de fatores, tais como o ambiente legal, a estrutura de garantias, o ciclo econômico e o próprio nível da taxa de juros.

E outro ponto a ressaltar, é que a taxa de juros dos empréstimos tem certa relação com a taxa Selic. A Selic afeta o custo de crédito por meio de seu efeito no custo de captação das IF's. A magnitude do repasse de reduções na taxa Selic para as taxas de juros dos empréstimos depende de diversos fatores, como o nível de ligação das diversas taxas de captação da IF com a taxa Selic e o peso que o custo de captação tem na composição do custo do crédito (REB, 2017).

Desta forma, ao analisar o período de 2015 a 2017 do ICC da Tabela 1, a contribuição do custo de captação caiu e a contribuição da inadimplência subiu, refletindo os impactos da flexibilização monetária e a recessão econômica brasileira. Já a contribuição dos tributos e FGC teve leve aumento em 2016, decorrente, em parte, da elevação de 15% para 20% da alíquota de CSLL para IF's ocorrida em setembro de 2015 (REB, 2017). O ICC médio ajustado chegou a seu auge em 2016 com 20.52% a.a. (Tabela 2), entrando em trajetória declinante a partir de 2017.

A partir de 2017, as condições de crédito se tornaram menos restritivas.⁵ Nos segmentos de pessoas físicas, as condições estavam ao redor ou próximas da

⁵ Pesquisa Trimestral sobre Condições de Crédito (PTC) de 2017 do BCB

neutralidade. Nos segmentos de pessoas jurídicas, as condições eram ainda consideradas restritivas, principalmente para micro, pequenas e médias empresas. Para estas, os principais fatores restritivos apontados foram as “Condições específicas dos clientes”, o “Nível de inadimplência” e o “Nível de tolerância ao risco”. Para as grandes empresas, destacou-se a melhora na percepção das condições gerais da economia doméstica ao longo de 2017, em linha com o processo de recuperação econômica (REB, 2017).

O mercado de crédito evoluiu de forma consistente com a recuperação da atividade econômica e os estímulos provenientes do atual ciclo de política monetária. Mas a recuperação veio de forma lenta. Ocorreram alguns acontecimentos negativos que contribuíram para esse crescimento fraco, como a greve dos caminhoneiros em 2018, Brumadinho, a crise argentina e a incerteza internacional com a guerra comercial entre EUA e China em 2019. Mas de toda forma esse período não apresenta variações significativas dos indicadores de crédito. Como se fosse o comportamento “típico” — estagnação.

Em 2020, veio a pandemia da Covid-19. O novo coronavírus coloca 2020 como um dos anos mais marcantes da história. Além das evidentes implicações no setor de saúde, a expansão da doença resultou em mudanças radicais em outros diversos vieses da, até então conhecida, normalidade social.

No período da pandemia, o ICC, a taxa de juros e a inadimplência apresentaram flutuações significantes — o comportamento dos parâmetros se desviaram da média. Desde o início da pandemia, os componentes do custo do crédito têm sofrido acentuadas quedas. Em outubro de 2020, o ICC atingiu 16.76% a.a. e a inadimplência 2.12%. E em julho de 2020 a taxa de juros chegou ao menor patamar da história, com a média ao mês de 1.39%.

Parte do bom comportamento dos indicadores pode ser explicado pelas ações governamentais e medidas bancárias que subsidiaram e baratearam o crédito, afim de combater, ou suavizar, os efeitos da paralisação das atividades.

A postergação do pagamento de impostos e o Programa de Manutenção do Emprego e da Renda (BEm) ofereceram um fôlego financeiro às empresas através da possibilidade de redução da jornada de trabalho e salário dos empregados. O

BCB lançou algumas medidas no primeiro semestre de 2020 e uma delas foi o programa de repactuações de dívidas⁶, que incentivou as IF's a renegociar dívidas com taxas menores.

Programas como o Pronampe⁷, PEAC⁸ e PESE⁹ foram fundamentais para que milhares de empresas mantivessem o fluxo de capital e funcionários, sem declarar falência. O Pronampe, um dos mais importantes programas, oferece crédito aos pequenos negócios e empresas. Os juros são menores e os prazos dilatados. Milhares de empresas que nunca tomaram empréstimos por conta de dificuldades históricas e restrições, conseguiram entrar no SFN.

Além disso, o Auxílio Emergencial¹⁰ oferecido à população sem renda, ou que perderam durante a pandemia, fez com que as famílias priorizassem o pagamento de dívidas e bens essenciais, dado a incerteza futura. Esse auxílio foi pago em cinco parcelas de R\$ 600 ou R\$ 1.2 mil para mães chefes de família monoparental e, depois, estendido até 31 de dezembro de 2020 em até quatro parcelas de R\$ 300 ou R\$ 600 cada.

Sobre os componentes do ICC em 2020 (Tabela 2), o custo de captação caiu, assim como em 2017, refletindo a flexibilização monetária. A meta para a taxa Selic, depois de ficar estável em 6.50% a.a. entre março de 2018 e julho de 2019, entrou em trajetória de declínio, aprofundada com a eclosão da pandemia da Covid-19, atingindo 2% a.a. em agosto de 2020.

A contribuição das despesas administrativas em pontos percentuais diminuiu, assim como a da margem financeira. Em relação ao componente tributos e FGC, observou-se praticamente uma estabilidade. Se, por um lado, a redução da alíquota do IOF no âmbito das medidas de combate aos efeitos da pandemia contribuiu para a queda desse componente, por outro, o aumento da alíquota de CSLL de 15% para 20% a partir do mês de março de 2020 atuou em sentido contrário.

⁶ Resolução 4.782, de 16 de março de 2020, prorrogada pela Resolução 4.856, de 24 de setembro de 2020

⁷ Programa de Apoio às Microempresas e Empresas de Pequeno Porte: Lei nº 13.999, de 18 de maio de 2020

⁸ Programa Emergencial de Acesso ao Crédito: Lei nº 14.042, de 19 de agosto de 2020

⁹ Programa Emergencial de Suporte a Empregos: Lei nº 14.042, de 19 de agosto de 2020

¹⁰ Lei nº 13.982, de 02 de abril de 2020

Com todas essas medidas, programas e auxílios, o ICC, a taxa de juros e a inadimplência, para pessoas e empresas, caíram de uma forma totalmente inesperada durante o período da pandemia da Covid-19.

Independentemente do período, outro fator válido é o nível de concentração bancária no mercado de crédito. Se existem apenas alguns bancos disponíveis para fornecer crédito, o custo do crédito aumenta, pois podem cobrar juros mais altos por não haver opção mais barata. Considerando o segmento bancário das operações de crédito, o índice de concentração bancária (denotado de Índice *Herfindahl-Hirschman* Normalizado) em 2015 era de 0.15 e em 2016 era de 0.16, onde a soma das participações das cinco maiores IF's (RC5) no mercado de crédito representava 80.9% e 83.3% respectivamente. Em 2020, o índice era de 0.13 e o RC5 representava 79.2% (REB, 2020). Sendo assim, a competitividade no mercado de crédito tem aumentado, e soluções financeiras recentes, como *open banking* e as *fintechs*, têm parcela relevante nesse resultado.

O aspecto concorrencial afeta primordialmente o componente da margem financeira do custo de crédito, por meio dos lucros. Ainda que esse seja o componente com menor peso no *spread* do ICC, ampliar a concorrência é prioridade e se insere no pilar “Crédito mais barato” da Agenda BCB + (REB, 2017).

1.7 Conclusão

Neste estudo, foi analisado a existência de quebras estruturais nas séries de indicadores do custo do crédito no Brasil entre janeiro de 2013 a junho de 2021. Testam-se se os pontos de mudanças estruturais apresentam origem em determinados eventos históricos. A metodologia utilizada foi o processo de flutuação M-generalizada baseada na regressão beta (ZEILEIS, 2006). A estatística teste consiste na hipótese de constância dos parâmetros contra a alternativa de flutuações excessivas.

Os resultados sugerem que a recessão econômica iniciada no final de 2014 influenciou na mudança dos parâmetros das séries do ICC e *spread*, enquanto que a pandemia da Covid-19 iniciada em 2020 afetou o ICC, a taxa de juros e a inadimplência.

A crise de 2015/2016 impactou negativamente o comportamento das séries do ICC e principalmente do *spread*, já que resultou em desalavancagens financeiras de famílias e empresas. O custo de crédito nesse período foi às alturas, acompanhado da inadimplência. A prevalência da inadimplência depende de uma série de fatores, tais como o ambiente legal, a estrutura de garantias, o ciclo econômico e o próprio nível da taxa de juros, que chegou a dois dígitos durante a crise.

Em 2020, veio a pandemia, e as medidas do governo federal e bancos brasileiros reduziram substancialmente os indicadores do custo do crédito, postergando ou mesmo reduzindo tributos dos empréstimos. Isso foi possível graças ao lançamento de programas de crédito às empresas e o auxílio financeiro oferecido à população sem renda. Nesse período, o ICC, a taxa de juros e a inadimplência atingiram os menores níveis desde 2013 e apresentaram flutuações significativas.

Em resumo, a quase última década foi desastrosa do ponto de vista do crescimento econômico pelo somatório de três fatores: forte recessão (picos de alta do custo do crédito: quebra significativa), recuperação lenta e gradual (estabilidade) e coronavírus (picos de queda do custo do crédito: quebra significativa). As piores consequências é o desemprego e a incerteza econômica, que não param de crescer.

Com o retorno das atividades econômicas, após meses de restrições no auge da pandemia, um início de aumento dos indicadores se manifesta. Embora a real extensão dos danos provocados pela crise ainda seja imprevisível, é inegável que ela afetará o futuro do crédito brasileiro.

2 Elasticidade prazo e taxa de juros sobre a demanda de crédito livre e direcionado

2.1 Introdução

O desenvolvimento do crédito é indiscutível para a economia de um país, pois permite o aumento da demanda e o acesso a bens de consumo, isso sem falar da indispensabilidade para investimentos de todos os tipos. Dentre os debates sobre crédito no Brasil, a avaliação do crédito livre (CL) e crédito direcionado (CD) tem grande destaque recente (SILVA, 2015); (NEGRI et al., 2018). A principal razão para isso é a gradual mudança da composição do mercado creditício nos últimos anos onde o CD tem adotado um papel protagonista.

Por definição, o CL é aquele em que os bancos têm autonomia para emprestar o dinheiro captado no mercado e definir as taxas de juros cobradas dos clientes — crédito privado. Já o CD tem regras definidas pelo governo, e é destinado, basicamente, aos setores habitacional, rural, de infraestrutura e ao microcrédito — crédito público.

Olhando para a última década, a oferta de ambos os segmentos tem crescido lentamente. Exclusivamente de 2016 a meados de 2017, houve estagnação do crédito, o CD se igualou ao CL, e em alguns momentos, foi superior. Atualmente, o saldo total da carteira ativa de CL é em média 40% maior do que o de CD. Em junho de 2021 o saldo de CL é um total de R\$2.4 trilhões e o saldo de CD um total de R\$1.7 trilhões.¹

De toda forma, a relação do crédito privado sobre o PIB (Produto Interno Bruto) brasileiro é inferior aos demais países no mundo (SILVA, 2015); (NEGRI et al., 2018). No período de 2003-2005 essa relação era de apenas 25%. Entre

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

2013 e 2015 essa relação aumentou para 50%. No mesmo período, essa parcela correspondia a 70% no Chile e 120% na África do Sul. Apenas um pequeno número de empresas e indivíduos consegue se livrar das restrições do mercado de crédito brasileiro. O financiamento de longo prazo é ainda mais carente, em especial para atividades que envolvem risco tecnológico. O investimento em inovação, ciência e tecnologia é imprescindível para recuperar e acelerar o crescimento da renda per capita (BONOMO; MARTINS, 2016); (BARBOZA, 2015).

O CL e o CD apresentam grande disparidade de políticas dado os prazos e os juros dos empréstimos. A taxa de juros do CL é em média 3.9 vezes maior que a taxa de juros do CD (2.73×0.69). Os juros do CD não apresentam grandes variações desde 2013, enquanto que no caso do CL, essa taxa tem alta em outubro de 2016, com 3.61% a.m. e menor valor em setembro de 2020, com 1.91% a.m.. Em relação ao prazo médio da carteira, o padrão muda. Os prazos médio para CL são constantes em torno de 19 meses, e para o CD, essa média vem crescendo com o passar dos anos — em janeiro de 2013 era de 65 meses e em junho de 2021, 94 meses (REB, 2020).

Dessa forma, o protagonismo do CD relatado anteriormente apoia-se nos momentos de crise, quando os bancos públicos conseguem agir de forma anticíclica aos bancos privados e expandir sua oferta. Não somente porque são frequentemente regulamentados, mas também porque possuem fontes de recursos de maior prazo e menor custo para lastrear suas operações. Essa evolução de comportamento é importante de ser entendida.

À vista disso, o objetivo desse artigo é avaliar a elasticidade da taxa de juros e prazo sobre a demanda de CL e CD, como também a relação cruzada dessas variáveis. A elasticidade é calculada por meio de um modelo de regressão log – log, e por isso, tanto nas variáveis explicativas quanto na variável resposta, aplica-se a função logarítmica. Já o termo cruzado refere-se a ideia de que a taxa de juros ou prazo de um tipo de crédito afeta a quantidade demandada do outro tipo de crédito.

O banco de dados é disponibilizado no Sistema Gerenciador de Séries Temporais (SGS) do Banco Central do Brasil (BCB) e varia de janeiro de 2013 a junho

de 2021. Outro ponto relevante é o período de aplicação do modelo. Como o comportamento do saldo dado o prazo e juros pode diferir dado o momento econômico, os modelos de elasticidades foram aplicados em períodos distintos de acordo com as datas de mudanças significativas de uma análise de quebras estruturais múltiplas para modelos de regressão linear (BAI; PERRON, 1995); (BAI; PERRON, 2003).

O trabalho se divide em seções. Na primeira Seção tem-se o referencial teórico (Seção 2.2), que aborda o mercado de CL e CD no Brasil e também os artigos que estudam a elasticidade sobre a demanda de crédito. Seguidamente, o método é apresentado na Seção 2.4, os dados na Seção 2.5, os resultados na Seção 2.6, a discussão na Seção 2.7 e por fim, a conclusão na Seção 2.8.

2.2 Referencial teórico

A avaliação da elasticidade da demanda de crédito tem ampla literatura científica. Geralmente, deseja-se saber o efeito de variáveis explicativas como a taxa de juros, prazo, preço, renda, dentre outras, sobre a demanda de empréstimos.

No trabalho de BECK, por exemplo, investiga-se a diferença nas respostas dos consumidores às mudanças no preço, nível da taxa de juros, renda e sentimento do consumidor sobre a demanda de automóveis. Os empréstimos variam mensalmente de 1987 a 2002. Os coeficientes para preço e taxa de juros são negativos (-2.16; -0.34), o coeficiente para renda é positivo (1.79) e o sentimento do consumidor não é significativo. Dessa forma, reduzindo preço ou juros ou aumentando a renda pessoal do indivíduos a venda de veículos aumenta.

DEHEJIA; MORDUCH; MONTGOMERY usam dados da *SafeSave*, uma cooperativa de crédito de Bangladesh, para examinar a sensibilidade dos tomadores de empréstimos aos aumentos nas taxas de juros. No total, são 5,147 clientes observados mensalmente de 1999 a 2001. Comparando três filias que apresentam produtos e preços levemente diferentes, as elasticidades juros da demanda de empréstimos variam de -0.73 a -1.04. Os correntistas menos ricos são mais sensíveis à taxa de juros do que os mutuários relativamente mais ricos (-0.86 em comparação a -0.26).

KARLAN; ZINMAN testam hipóteses com foco na demanda por microcrédito usando uma *survey* na África do Sul. Os resultados apontam elasticidades de -0.14 a -0.51 de acordo com características do indivíduo (sexo e renda) e do tamanho do empréstimo. A elasticidade juros da demanda de crédito é menor para os clientes mais avessos ao risco e os mais pobres não reagiram tanto no preço. Já o tamanho do empréstimo é muito mais sensível às mudanças no prazo do que às mudanças nas taxas de juros.

BOGAN; TURVEY; SALAZAR utilizam uma *survey* de 229 clientes da *Esperanza International*, que opera no Haiti e República Dominicana. A amostra compreende os meses de julho e agosto de 2019. Junto às informações coletadas foram agregadas informações de crédito do conjunto de dados *Esperanza*. Como desfecho, a demanda por microcrédito se torna mais elástica quando as taxas de juros caem e mais inelásticas à medida que as taxas de juros aumentam (-1.38 a -0.63). Além disso, efeitos positivos foram encontradas com relação ao nível de habilidade empreendedora.

Os artigos a seguir tem foco em dados de crédito brasileiro.

COELHO; MELLO; GARCIA propõem um método para identificação da oferta e demanda de crédito da economia brasileira de 2000 a 2006 usando parâmetros heterocedásticos. As elasticidades juros para capital de giro e crédito ao consumidor variam de acordo com o tamanho do banco. Os bancos reagem aos choques de política monetária num padrão inverso ao que se observa na economia americana. Os grandes bancos apresentam maior sensibilidade aos choques do que os pequenos.

FERMAN analisa a sensibilidade do tomador de empréstimo à taxa de juros quando ela é ou não divulgada por uma companhia de cartão de crédito. A amostra é composta por 19,690 clientes em julho ou setembro de 2010. Os resultados apontam que quando a taxa de juros não é divulgada a elasticidade juros da demanda de crédito é de -0.88 para tomadores de baixo risco, -0.51 para clientes de médio risco e -0.16 para tomadores de maior risco. Quando é revelada, o impacto é consideravelmente maior para os tomadores de maior risco -0.90 enquanto que para o restante não apresenta diferença significativa.

BEZERRA; LIMA; SILVA avalia o canal de crédito bancário por meio de funções impulso resposta empíricas, obtidas de um modelo VECM (*vector error correction model*), e teóricas, originadas de um modelo DSGE (*Dynamic Stochastic General Equilibrium*). A metodologia utilizada permite identificar os componentes de demanda e da oferta dos empréstimos na presença de choques na política monetária. Os dados são mensais e variam de 2006 a 2012. Os resultados sugerem que a demanda por empréstimos varia negativamente com a taxa de juros (-0.025) e positivamente com a renda (3.04).

MENDONÇA; MOREIRA; SACHSIDA estimam a elasticidade juros da demanda por crédito para a compra de automóveis, de 2000 a 2012. Foram usados modelos de *Markov switching* com variável endógena para captar regimes distintos na função de estimativa. Esses regimes compreendem um período de expansão (2004 a 2007), um de retração (2007 ao início de 2008) e o outro de expansão, até 2009, fomentadas por medidas anticíclicas do governo. Informações como a taxa e prazo de financiamento, preço do veículo e estado da economia (taxa de crescimento do PIB como *proxy*) são utilizadas como variáveis explicativas do modelo. As conclusões indicam elasticidades negativa da taxa de juros (-0.026 a -0.212) e positivas mas não significantes do prazo, PIB e preço.


O estudo de NEGRI et al., inspiração para esse estudo, explora a elasticidade da demanda de CD e CL por empresas brasileiras. A amostra compreende 378,651 empresas entre 2004 a 2017. A elasticidade juros para CL é negativa e para CD é positiva (contra-intuitivo). Já os prazos tem efeito positivo na demanda por qualquer um dos créditos. As estimativas mostram que os juros são mais importantes na decisão da empresa contratar CL e os prazos são mais relevantes na contratação de CD. As elasticidades cruzadas dos juros indicam que CL e CD são pouco correlacionados.

Em resumo, a taxa de juros possui elasticidade negativa em relação a demanda de crédito de forma unânime. O prazo, espera-se um efeito positivo, mas em alguns casos não apresenta estimativa significativa. Outro ponto importante, é que o momento econômico pode mudar o sentido do efeito das variáveis e por isso é válida a investigação em diferentes períodos (MENDONÇA; MOREIRA; SACHSIDA, 2017).

2.3 Mercado de crédito livre e direcionado

As Figuras 9, 10 e 11 demonstram o comportamento dos indicadores do saldo da carteira ativa (em milhões de reais), taxa de juros (em % a.m.) e prazo médio da carteira (em meses), segmentados por tipo de crédito e total. Os dados podem ser acessados através do SGS² e variam de janeiro de 2013 até junho de 2021.

Figura 9 – Saldo da carteira ativa total x crédito livre x crédito direcionado



² <<https://www3.bcb.gov.br/sgspub/localizarseries/localizarSeries.do?method=prepararTelaLocalizarSeries>>

Figura 10 – Taxa de juros x crédito livre x crédito direcionado





Figura 11 – Prazo da carteira ativa total x crédito livre x crédito direcionado



O saldo da carteira ativa determina a quantidade em milhões de reais das operações de crédito no Sistema Financeiro Nacional (SFN). A fim de expurgar o

efeito inflacionário dos preços, os valores foram deflacionados pelo Índice de Preços ao Consumidor Amplo (IPCA)³. Em janeiro de 2013 o saldo total é de R\$3.7 trilhões, atingindo em junho de 2021 a quantidade de R\$4.2 trilhões (Figura 9). Considerando o mesmo período, o saldo de CL inicial é de R\$2.1 e final de R\$2.4 trilhões; e o saldo de CD inicial é de R\$1.5 e final de R\$1.7 trilhões. Aqui, é importante sinalar que durante o período de 2016 a 2017, os saldos de CL e CD se igualaram, principalmente por conta da redução do CL e estagnação do CD (Figura 10).

A taxa de juros é o índice que o tomador deve pagar ao proprietário do capital emprestado, pois o segundo abre mão da liquidez imediata em favor de rendimentos futuros. As séries se iniciam num patamar de 2.19% a.m. para CL e 0.59% a.m. para CD; de 2016 a 2017 sofrem um pico, a taxa de juros de CL atinge 3.6% a.m e de CD quase 1% a.m.; após isto, vem sofrendo reduções; e em junho de 2021 tem o mesmo patamar do início de 2013.

O prazo médio da carteira mensura o tempo médio em meses de duração dos empréstimos. Este apresenta comportamento muito similar entre os segmentos de crédito, mas em magnitudes diferentes (Figura 11). No começo da série, o prazo médio total aponta para 38 meses, atingindo 55 meses em junho de 2021. O prazo para CD é maior do que para o CL, em janeiro de 2013 têm-se os valores de 65 x 16 e no final da série, 94 x 21 meses em média.

A inadimplência do CL é maior do que a inadimplência do CD. Em 2013 era 5 vezes maior (5.2% x 1.0%). Ao longo dos anos, a inadimplência do CL vem reduzindo e em junho de 2021 é de apenas 2.9%; já a do CD não sofre tantas variações e atualmente está em 1.3%. Em ambos os segmentos, a inadimplência teve alta no período de 2016 e 2017, atingindo em maio de 2017, 5.9% para CL e 2.1% para CD. As menores taxas estão concentradas no período da pandemia da Covid-19.

Do total do saldo de junho de 2021 (4.2 trilhões), 43% são de PJ's e 57% são de PF's. No caso do CL (2.4 trilhões - 59% do total), 47% são de PJ's e 53%

³ Série histórica do IPCA geral disponível no Ipeadata: <<http://www.ipeadata.gov.br>>. A data-base do índice foi a de junho de 2021, com o objetivo de trazer uma percepção dos valores hoje.

são de PF's. Para CD (1.7 trilhões - 41% do total), 38% são de PJ's e 62% são de PF's — anteriormente a abril de 2017 o saldo era maior para PJ. De toda forma, atualmente, o CD dispara para PF enquanto que o CL é mais equiparado.

Sobre as modalidades do CL de PJ's (1.1 trilhões do 2.4 trilhões total), 39% do saldo é para capital de giro, seguido de desconto de duplicatas e recebíveis (13%) e financiamento a exportações (9%). Sobre as modalidades do CL de PF's (1.3 trilhões de 2.4 trilhões total), 36% é crédito pessoal consignado total (para trabalhadores, aposentados e pensionistas do INSS), seguido de 23% para cartão de crédito total (rotativo, parcelado e à vista) e 19% para aquisição de bens (veículos e outros).

Sobre as modalidades do CD de PJ's (0.7 trilhões do 1.7 trilhões total), 56% do saldo é de financiamento com recursos do BNDES total, seguido de outros créditos direcionados (33%) e de crédito rural (7%). Sobre as modalidades do CD de PF's (1 trilhão de 1.7 trilhões total), 70% é para financiamento imobiliário, seguido de 24% para crédito rural e 5% para financiamento com recursos do Banco Nacional de Desenvolvimento Econômico e Social (BNDES).

O crédito para investimentos das empresas é realizado, em grande parte, por meio de operações diretas e repasses do BNDES. Os financiamentos habitacionais das famílias são primordialmente concedidos no âmbito do Sistema Financeiro da Habitação (SFH), sendo a principal instituição financiadora a Caixa Econômica Federal (CEF). O crédito rural é especialidade do Sistema Nacional de Crédito Rural (SNCR), que tem o Banco do Brasil (BB) como principal agente financiador (LUNDBERG, 2011), (REB, 2020).

Como visto, as variáveis que caracterizam o CL e o CD, além de possuírem amplitudes bastante diferentes, os comportamentos respectivos variam de formas particulares dado o momento econômico. Portanto, o modelo de elasticidade aplicado em diferentes períodos pode ajudar a entender a variação do efeito dos prazos e juros na demanda de ambos os segmentos, e ainda, a diferença entre eles.

2.4 Método

Para cálculo das elasticidades, utiliza-se o logaritmo das variáveis resposta e explicativas em um modelo de regressão. No caso de um modelo log – log, a elasticidade é um valor constante em toda a curva da série de tempo. Os coeficientes β_i representam as elasticidades prazo e juros da demanda de CL ou CD (representada pelo saldo da carteira ativa de cada tipo de crédito). A equação estimada tem a forma (HURSH, 1980), (HURSH, 1984):

$$\log(\text{saldo}) = \beta_1 \times \log(\text{prazo}) + \beta_2 \times \log(\text{juros}) \quad (2.1)$$

Aqui, a interpretação é que o aumento de 1% na covariável de prazo ou juros está associada a um acréscimo (quando positivo) ou a um decréscimo (quando negativo) de $\beta\%$ no log da demanda de crédito, em média.

Como observado na Seção 2.3, as demandas de CL e CD não possuem comportamentos lineares. E portanto ajustar uma regressão linear em todo o conjunto de dados não parece algo adequado. Logo, o modelo de elasticidade será aplicado em períodos distintos a partir de pontos de mudanças significativos. As datas são encontradas simultaneamente por meio da análise de quebras estruturais múltiplas (BAI; PERRON, 2003).

Essa metodologia é amplamente aplicada nas ciências econômicas para capturar o comportamento assimétrico observado em expansões e recessões (HAMILTON, 1989), (WOHAR; RAPACH, 2005), (KIM; MORLEY; NELSON, 2005), (BISWAS, 2020), (PARAB; REDDY, 2019). Assim, se aplica bem ao objetivo desse estudo. A implementação no ambiente R de computação estatística (R Core Team, 2020) podem ser consultadas em (ZEILEIS et al., 2003).

2.5 Dados

O SGS⁴ contém valores mensais dos principais indicadores de crédito brasileiro das operações no SFN. As séries temporais compreendem o período de janeiro

⁴ <<https://www3.bcb.gov.br/sgspub/localizarseries/localizarSeries.do?method=prepararTelaLocalizarSeries>>

de 2013 a junho de 2021. De acordo com o Glossário de crédito do Banco Central, as definições para saldo, prazo e taxa de juros são:⁵

- Saldo total da carteira ativa: corresponde ao somatório do saldo devedor dos contratos de crédito em final de mês. Inclui as novas concessões liberadas no mês e a apropriação de juros pró-rata das operações de empréstimos e financiamentos;
- Prazo médio da carteira: média dos prazos de cada pagamento (em meses) ponderada pelo respectivo valor. No caso das operações em atraso, são consideradas somente as carteiras com atraso até noventa dias, cujo prazo considerado na apuração é de 1 (um) dia;
- Taxa média de juros: média das taxas de juros das concessões, ponderada pelos respectivos valores desembolsados. As taxas médias dos segmentos agregados (total, pessoa jurídica e pessoa física, livre e direcionado) são apuradas pelas taxas médias das modalidades, ponderadas pelos saldos médios das respectivas carteiras.

Todos os indicadores são particionados por CL e CD.

As operações de crédito com recursos livres correspondem aos contratos de financiamentos e empréstimos com taxas de juros livremente pactuadas entre IF's e mutuários. Aqui, as IF's têm autonomia sobre a destinação dos recursos captados em mercado.

As operações de crédito com recursos direcionados são regulamentadas pelo Conselho Monetário Nacional (CMN) ou vinculadas a recursos orçamentários destinadas, basicamente, à produção e ao investimento de médio e longo prazos aos setores imobiliário, rural e de infraestrutura. As fontes de recursos são oriundas de parcelas das captações de depósitos à vista e de caderneta de poupança, além de fundos e programas públicos.

⁵ <https://www.bcb.gov.br/content/estatisticas/docs_estatisticasmonetariascredito/glossariocredito.pdf>


2.6 Resultados

Primeiramente, definem-se os períodos de aplicação do modelo de elasticidade através de uma análise de quebras estruturais múltiplas (JUSHAN; PERRON, 1998); (BAI; PERRON, 2003).

Como resultado na estimação da demanda de crédito total, as datas de mudanças significativas ocorrem em fevereiro de 2016 e fevereiro de 2020 — sendo esse o número ótimo de quebras estimadas na série do saldo dado o prazo e juros. Dessa forma, três períodos são construídos: período 1: de jan/2013 a jan/2016; período 2: de fev/2016 a jan/20; e período 3: de fev/2020 a junho/2021 (Figura 12). Esses intervalos de quebras serão estendidos para a análise particionada do CL e CD.

Entende-se que o período 1 e 3 é de crescimento do crédito e o período 2 é de estagnação do crédito. Essas suposições seguem em linha com a análise exploratória dos dados realizada na Seção 2.3.

Figura 12 – Períodos



Os resultados dos modelos de elasticidade está na Tabela 7. Estimam-se as elasticidades das covariáveis prazo e juros sobre a demanda de CL, CD e também

para a soma dos dois, empréstimos no geral.⁶ Os resultados são obtidos para os períodos 1, 2, 3 e também para a amostra total: janeiro de 2013 a junho de 2021.

Tabela 7 – Elasticidades prazo e juros da demanda de crédito

Resposta	Covariável	Período 1	Período 2	Período 3	Total
CL + CD	Prazo	1.40*	-0.69	2.78*	1.08*
	Juros	-0.14*	-0.29*	0.37	-0.24*
CL	Prazo	0.04	0.71	-1.27	1.47*
	Juros	0.33*	-0.36*	-0.77*	-0.35*
CD	Prazo	3.27*	-0.33*	3.37*	0.93*
	Juros	-0.06	0,05*	0.29	0.46*

* = p-valor significativa a 0.05.

Ao considerar o período total, a demanda de crédito total é afetada positivamente pelo prazo (1.08) e negativamente pela taxa de juros (-0.24). A demanda de CL segue o mesmo comportamento, positivo para prazo (1.47) e negativo para juros (-0.35). Já a demanda de CD tem efeito positivo do prazo (0.93) e também positivo dos juros (0.46).

Olhando para os períodos separadamente, o prazo tem elasticidade positiva na demanda de crédito total nos períodos 1 (1.40) e 3 (2.78) e não significativa no período 2. Já a taxa de juros tem elasticidade negativa no período 1 (-0.14) e 2 (-0.29) e não significativa no período 3.

Dado o objetivo de comparar os dois segmentos de crédito, privado e público, analisa-se também a elasticidade segmentada. Em relação à demanda de CL, o prazo não é significativo em nenhum dos períodos; e a taxa de juros é positiva no período 1 (0.33) e negativa nos períodos 2 (-0.36) e 3 (-0.77). Em relação à demanda de CD, o prazo tem elasticidade positiva nos períodos 1 (3.27) e 3 (3.37) e negativa no período 2 (-0.33); e a taxa de juros só tem coeficiente significativo, ainda que próximo a zero, no período 2 (0.05).

Outra análise sugerida, é a elasticidade cruzada dos prazos e juros de um tipo de crédito na demanda do outro tipo de crédito. As estimativas encontram-se na Tabela 8.

⁶ Nesse estudo, as elasticidades sobre a demanda de crédito se referem ao seu logaritmo.

Tabela 8 – Elasticidades cruzadas prazo e juros da demanda de crédito

Resposta	Covariável	Período 1	Período 2	Período 3	Total
CL	Prazo CD	1.01*	1.76*	2.94*	1.17*
	Juros CD	-0.00	0.14	0.24	0.30*
CD	Prazo CL	-0.45	-0.01	-0.91	1.40*
	Juros CL	1.24*	0.18*	-0.80*	0.30*

* = p-valor significante a 0.05.

A elasticidade cruzada sobre a demanda de CL em relação ao prazo do CD é de 1.17; e em relação aos juros é de 0.30. E a elasticidade cruzada sobre a demanda de CD em relação ao prazo do CL é de 1.40; e em relação aos juros é de 0.30.

Acerca dos períodos, os coeficientes significantes são dos prazos do CD sobre a demanda de CL e dos juros do CL sobre a demanda de CD. Quando os prazos do CD aumentam, a demanda de CL aumenta. E o peso dessa variação cresce ao longo dos anos. Quanto aos juros do CL, há diferenças. No período de 2013 a 2019 (1 e 2), quando os juros do CL aumentam a demanda de CD aumenta (1.24 e 0.18). Já no período 3, seu efeito é oposto (-0.80).

2.7 Discussão

A elasticidade juros total é negativa e segue a literatura (Tabela 7). Quanto maior a taxa de juros dos empréstimos, menor é a demanda de crédito. Os resultados sugerem que o aumento de 1% na taxa de juros está associado a redução de 0.24% no log da demanda de crédito.

Quando categorizado por tipo de crédito, essa afirmativa não é válida para o CD. No crédito público, aumentando os juros, a demanda é maior (0.46) — assim como encontrado em [NEGRI et al.](#). Esse resultado não tem interpretação direta do ponto de vista econômico, mas alguns pontos podem ser levantados. Primeiro, a parcela da taxa de juros pré-fixada na taxa de juros final do CD é maior, em especial por conta da forma de fixação da Taxa de Juros de Longo Prazo (TJLP) e assim, um aumento na taxa de juros pode aumentar a procura por CD, e mesmo que este ao final fique mais caro, o nível dos juros continuaria sendo o mais baixo

entre os tipos de crédito. Segundo, é possível que ocorra uma defasagem de tempo entre a decisão de demandar crédito das PF's e PJ's e a aprovação por parte da IF. O prazo médio de aprovação e contratação do CD em bancos como CEF, BB ou BNDES pode ser superior a um ano. Portanto, podem ocorrer variações nos juros que não estão pareados com a decisão de investimento.

Além da análise no período total (jan/2013 a jun/21), foram analisados três momentos distintos: 2013 ao primeiro semestre de 2016 (crescimento do saldo), segundo semestre de 2016 a 2019 (retração do saldo) e de 2020 a 2021 (crescimento do saldo). Dado o pequeno tamanho da amostra, já que os dados são mensais, algumas das elasticidades não têm valor significativo.

No período 3, intervalo da pandemia da Covid-19, o prazo total tem elasticidade duas vezes maior (2.78) do que no período inicial (1.40). Isso indica que os prazos no momento da pandemia são mais importantes na decisão de tomar crédito. E outro ponto é que, a elasticidade prazo para a demanda de CD, empréstimos de maiores durações, tem ainda maior efeito, em torno de 3.3%. Enquanto que os juros são mais importantes para o CL e seu efeito é negativo (-0.77).

No ano de 2020, o governo e bancos brasileiros lançaram diversas medidas de apoio às empresas como, o Programa de Apoio às Microempresas e Empresas de Pequeno Porte (Pronampe)⁷, o Programa Emergencial de Acesso ao Crédito (PEAC)⁸, o Programa Emergencial de Suporte a Empregos (PESE)⁹ e o BNDES Crédito Pequenas Empresas. Com o Pronampe, por exemplo, os empréstimos são facilitados, já que o empréstimo tem como garantia recursos de um fundo público. Em contrapartida, as empresas assumem o compromisso de preservar o número de funcionários. Aqui, empresas e indivíduos são beneficiados com a manutenção das atividades e dos salários.

Às famílias, o Auxílio Emergencial (AE)¹⁰ foi um importe suporte para injetar dinheiro aos que não possuíam renda ou perderam durante a pandemia. Com dinheiro em mãos, a população brasileira deu prioridade à quitação de suas

⁷ Lei nº 13.999, de 18 de maio de 2020.

⁸ Lei nº 14.042, de 19 de agosto de 2020.

⁹ Lei nº 14.042, de 19 de agosto de 2020.

¹⁰ Lei nº 13.982, de 02 de abril de 2020.

dívidas, dado a incerteza futura de uma renda futura, e a inadimplência chegou aos menores níveis da história.

Outra oportunidade importante, foram os programas de renegociação de dívidas¹¹, que na prática, estenderam os prazos de pagamento. Assim, os prazos teriam ainda maior peso na escolha de tomar crédito. No caso do crédito subsidiado, a maturidade dos empréstimos é mais importante que o preço (KARLAN; ZINMAN, 2008).

No período de 2013 a 2016, os juros do CL tem efeito positivo (0.33) na demanda de CL. O que parece contraintuitivo. Em momentos de recessão econômica, o comportamento do sistema de crédito pode ser bem conturbado. Externalidades negativas, variações excessivas da taxa básica de juros e falhas de mercado podem justificar a atuação em determinadas atividades ou mercados, que não poderiam ser suficientemente financiadas pelo setor privado. Assim, o aumento dos juros implicaria no aumento da demanda de crédito com recursos livres.

A elasticidade cruzada sobre a demanda de CL em relação ao prazo do CD é de 1.17 e dos juros de CD é de 0.30. E a elasticidade cruzada sobre a demanda de CD em relação ao prazo do CL é de 1.40 e dos juros de CL é de 0.30 (Tabela 8).

Esses resultados indicam que os mercados de CL e CD andam juntos e não possuem descolamento dado à variação dos indicadores da taxa de juros e prazo. Ou seja, aumentando os juros ou prazos de um tipo de crédito aumenta a demanda do outro tipo de crédito.

Em relação aos períodos, os coeficientes significantes são dos prazos do CD sobre a demanda de CL e dos juros do CL sobre a demanda de CD. Quanto aos prazos do CD, quando aumentam, a demanda de CL aumenta. E o peso da variação aumenta ao longo dos períodos (1.0; 1.76; 2.9). Quanto ao juros do CL, há diferenças. No período de 2013 a 2019 (1 e 2), quando os juros de CL aumentam a demanda de CD aumenta (1.24 e 0.18); e seu efeito é contrário no período 3 (-0.80).

¹¹ Resolução 4.782, de 16 de março de 2020, prorrogada pela Resolução 4.856, de 24 de setembro de 2020.

Isso corrobora a avaliação de que a elevação da taxa de juros do CL não influencia consideravelmente na demanda de CD, mas que uma elevação nos prazos do crédito público pode aumentar a demanda de crédito privado em até 2.9%.

2.8 Conclusão

Neste trabalho foram exploradas as elasticidades prazo e juros na demanda de crédito livre (CL) e crédito direcionado (CD). Esses dois tipos de recursos se diferem bastante quanto às políticas de crédito, em especial aos juros e prazos médios. No CL, as taxas são combinadas entre as partes interessadas e são maiores, e os prazos são menores. No CD, os juros são regulamentados pelo CMN e são menores, e os prazos são consideravelmente maiores.

A metodologia consiste na aplicação de modelos log – log em períodos encontrados por meio de uma análise estrutural múltipla, já que entre 2013 e 2021, a economia passou por diferentes momentos econômicos.

O período 1 compreende de jan/2013 a jan/2016, o período 2 compreende de fev/2016 a jan/2020 e o período 3 compreende de fev/2020 a jun/2021. O período 1 é marcado pela recessão econômica iniciada em 2014 e crescimento do saldo. O período 2 é de recuperação econômica e estagnação do crédito. E o período 3 é da ainda atual pandemia da Covid-19 e crescimento do saldo. O crescimento do saldo em períodos de crises é por razão dos incentivos ao crédito — flexibilização da política monetária, programas dos bancos, auxílios emergenciais, dentre outros.

Como resultados principais, têm-se:

R1: A demanda por crédito apresenta elasticidade negativa com respeito à taxa de juros (-0.24) e apresenta elasticidade positiva com respeito ao prazo (1.08). Quando segmentado por tipo de crédito, os juros tem efeito positivo (0.46) na demanda de CD. Isso pode ser justificado pela defasagem da aprovação do CD, o nível da taxa de juros que continuaria sendo o mais baixo e pela importância desse tipo de crédito para às empresas e famílias.

R2: Os prazos são mais importantes na decisão de tomar crédito público, principalmente no período da pandemia da Covid-19 (3.37). As elasticidades su-

gerem que a decisão de demandar ou não CD não está relacionado aos juros, mas sim aos prazos mais longos — que também sustenta o resultado anterior.

R3: As elasticidades cruzadas indicam que os mercados andam juntos. As taxas de juros e os prazos do CD no período 2013-2021 afetam positivamente a demanda pelo CL (1.17 e 0.30). As taxas de juros e os prazos do CD no período 2013-2021 afetam positivamente a demanda pelo CL (1.40 e 0.30).

A avaliação do CL e CD no Brasil ainda precisa ser melhor investigada, prioritariamente no período recente da pandemia. Os efeitos negativos da Covid-19 na demanda de crédito possivelmente ainda estão por vir. Algumas das razões são a normalização da atividade econômica, a necessidade de desalavancagem do endividamento da população brasileira, a redução das renegociações e postergações de dívidas, o fim de boa parte dos incentivos e auxílios do governo e bancos, o índice de desemprego e o aumento da inflação no ano de 2021.

3 Séries temporais em indicadores de crédito - período pandemia

3.1 Introdução

Em 31 de dezembro de 2019, a China anunciava o primeiro caso de contaminação pelo novo coronavírus. Em 11 de março de 2020, a Organização Mundial da Saúde reconhece a pandemia da SARS-CoV-2, comumente chamada de Covid-19. Desde então, a saúde pública como também a estabilidade econômica têm sido fortemente afetadas.

Diante do desconhecimento quase completo das características do novo vírus, as medidas de distanciamento e isolamento sociais foram formas de prevenção encontradas. Com o intuito de salvar vidas, tais ações geraram uma crise de oferta — já que trabalhadores foram impossibilitados de frequentar postos de trabalho; e uma crise de demanda — por causa da paralisação parcial ou total de atividades produtivas. Milhares de empresas fecharam e as rendas familiares foram impactadas. Nessas situações, o fornecimento de capital é uma saída para a sobrevivência e manutenção imediata das atividades.

No Brasil, diversas instituições buscaram contribuir no combate à crise. As Instituições Financeiras (IF's) ofereceram prazos maiores e juros menores, impulsionados pela recorrente diminuição da taxa Selic. O Banco Central do Brasil (BCB) lançou um conjunto de políticas monetárias e fiscais para garantir um sistema de crédito capitalizado, que sirva como canal para sustentar as operações de setores cruciais, apoiar as pessoas que estão proibidas de trabalhar e impedir a deterioração dos mercados e o mau funcionamento do sistema financeiro. Uma das primeiras ações do BCB foi a de adotar um programa de repactuação e renegociação de dívidas. Na prática, essa ação incentivou as IF's a estender os prazos de seus operações.

O Governo Federal deu início a alguns programas de suporte já no primeiro

semestre de 2020. O Auxílio Emergencial (AE), estabelecido em abril, trouxe um alívio financeiro às famílias. O Programa de Apoio às Microempresas e Empresas de Pequeno Porte (Pronampe) foi a principal linha de empréstimos com foco em custos essenciais do empreendimento, como aluguel, salários de colaboradores, ou até mesmo investimento em um novo modelo de trabalho, como *delivery* e vendas virtuais.

O Banco Nacional de Desenvolvimento Econômico e Social (BNDES) montou diversas linhas como o BNDES Crédito Pequenas Empresas, o Programa Emergencial de Acesso ao Crédito (PEAC) e o Programa Emergencial de Suporte a Empregos (PESE).

Perante a esse cenário, a pergunta principal desse estudo é se as ações do governo e IF's teriam mudado a tendência dos indicadores de crédito brasileiro durante o período da pandemia. E a hipótese é de que sim, contribuíram positivamente, tanto para a redução de taxas e inadimplência, como para o aumento de prazos e outras condições.

Por meio de dados advindos do Sistema Gerenciador de Series Temporais (SGS) do BCB, os indicadores de crédito avaliados são o saldo da carteira ativa, o prazo médio da carteira, a taxa média de juros e a inadimplência. As séries de tempo variam mensalmente de 2013 a junho de 2021. Diferentes modelos de séries temporais são aplicados para “prever” o período da pandemia (a partir de março de 2020), e assim comparar o comportamento esperado dos indicadores com o que realmente aconteceu. Os modelos utilizados são ARIMA, ARIMA com erros *XGboost*, ETS, *Prophet* e regressão linear. A título de discussão, algumas hipóteses e expectativas são levantadas.

O trabalho se divide em seções. Na primeira Seção tem-se o referencial teórico (Seção 3.2), que aborda o contexto econômico antes e durante a pandemia no Brasil e os artigos que aplicam modelos de séries temporais em dados sociais, econômicos ou políticos relacionados à pandemia. Seguidamente, os métodos são apresentados na Seção 3.3, os dados na Seção 3.4, os resultados na Seção 3.5, a discussão na Seção 3.6 e por fim, a conclusão na Seção 3.7.

3.2 Referencial Teórico

3.2.1 Contexto Econômico pré e durante pandemia - Brasil

Ao longo do primeiro semestre de 2019 a economia brasileira enfrentou três choques expressivos: a seca no Sul do país que afetou a produção agrícola; o desastre da barragem de Brumadinho que causou perda de vidas humanas e teve forte impacto na produção extrativa; e a crise na Argentina aliada a disputa Estados Unidos-China que aumentou a incerteza em relação ao comércio internacional.

Além desses infortúnios, o governo aprovou importantes medidas de combate a má alocação de recursos. O novo FGTS, o leilão de cessão onerosa, a lei do contribuinte legal, a lei de liberdade econômica, a nova lei do Agro, a modernização das normas regulamentadoras de saúde e segurança no trabalho, entre diversas outras iniciativas foram empregadas com sucesso. A Nova Previdência, com previsão de economizar mais de R\$ 800 bilhões em dez anos, aliada a esse conjunto de medidas para melhorar a produtividade brasileira geraram um ambiente propício para a redução natural das taxas de juros pagas nos títulos públicos. Dados do Tesouro Nacional, de fevereiro de 2020, sinalizavam que, com as reduções nas taxas de juros, o Brasil economizaria R\$ 419 bilhões em pagamentos com juros nos quatro anos seguintes.¹ Das três principais contas fiscais: previdência, juros e pessoal, restava apenas essa última para ser endereçada em 2020.

Entre prós e contras, o relatório Focus do BCB de fevereiro de 2020² colocava a mediana das projeções de crescimento da economia brasileira em 2.17%, ou seja, a economia brasileira estava em trajetória ascendente. Em outras palavras, os analistas de mercado esperavam um ano de recuperação econômica. Visão essa que seria arruinada com o advento da pandemia de Covid-19.

Para salvar vidas, medidas de isolamento e restrição social foram anunciadas. Para preservar empregos e empresas, auxílios financeiros, programas de incentivo ao crédito, postergação de dívidas e etc. foram saídas encontradas para evitar o declínio da economia. A ideia básica da política econômica foi manter a

¹ <<https://www.gov.br/economia/pt-br/centrais-de-conteudo/publicacoes/notas-informativas/2020/ni-a-evolucao-da-economia-ao-longo-de-2020.pdf>>

² <<https://www.bcb.gov.br/publicacoes/focus/cronologicos>>

estrutura produtiva funcionando durante o período da crise, mas que depois se mostraria uma retomada econômica ainda mais lenta e incerta.

3.2.2 Séries Temporais em indicadores econômicos - período pandemia

Sob a ótica do recente coronavírus, têm-se um impulso nos estudos sobre os efeitos da pandemia em indicadores econômicos, sociais ou políticos, de uma forma global.

[BECK; KEIL](#) mostram um aumento nas provisões para perdas e empréstimos inadimplentes em bancos dos EUA. Para os bancos mais afetados pela pandemia, tem-se uma redução no número e no valor médio dos empréstimos, bem como um aumento nos *spreads* de juros e diminuição nos vencimentos de pagamento.

[HASAN; POLITSIDIS; SHARMA](#) observam um crescimento em relação aos *spreads* sobre os empréstimos sindicados globais, em resposta ao aumento da exposição dos credores e devedores à pandemia, que é ainda mais exacerbada com o nível de restrições governamentais. Na mesma linha, [DAEHLER; AIZENMAN; JINJARAK](#) investigam os fatores que direcionam os *spreads* em *Credit Default Swaps* (CDS) de mercados emergentes, encontrando uma relação positiva entre *spreads* e CDS e a taxa de mortalidade acumulada da Covid-19. Os autores sugerem que a deterioração epidemiológica pode diminuir a confiança no mercado, devido às perspectivas de *lockdowns* prolongados e uma recuperação mais demorada da economia.

[NARAYAN; PHAN; LIU](#) avaliam os efeitos econômicos da Covid-19 em dados de séries temporais de ações. Em conclusão, os autores apontam que as políticas governamentais, por mitigarem a propagação do novo vírus e ajudarem a conter o pânico, tiveram um efeito positivo nos mercados de ações.

[DANISMAN; DEMIR; ZAREMBA](#) examinam se as diferenças nas estruturas do mercado bancário entre os países influenciam a resiliência do mercado de ações locais à pandemia. Usando uma amostra de 66 países para o período de janeiro de 2020 a julho de 2020, os resultados demonstram que, embora as reações das ações de países com sistemas bancários estáveis sejam mais resistentes, países com provisões elevadas e empréstimos inadimplentes são mais vulneráveis.

LOUHICHI; FTITI; AMEUR analisam o impacto da pandemia em indicadores econômicos da China, França, Itália e Estados Unidos, utilizando *Continuous Wavelet Transforms* (CWT). Os autores identificam diferentes padrões; na China, observam uma covariação entre a pandemia; enquanto nos demais países encontram um efeito mais persistente.

JORDÀ; SINGH; TAYLOR apontam que as taxas de juros básicas indica uma estagnação secular para a estabilização monetária e fiscal nas próximas duas décadas ou mais. Comparada à grande pandemia da influenza de 1918-1920, WENG mostra um alcance remoto da Covid-19, dados os avanços na saúde pública e as medidas que estão sendo tomadas para mitigar a propagação do novo vírus.

Sobre a aplicação e comparação de modelos de séries temporais, CHAURASIA; PAL implementam técnicas de previsão de mortes causadas pela Covid-19. As técnicas aplicadas são: *naive*, média simples, média móvel, suavização exponencial única, método de tendência linear de *Holt*, método de *Holt-Winters* e ARIMA. Em conclusão, os métodos *naive* e ARIMA apresentam o melhor ajuste. E dessa forma, podem ser utilizados para guiar o governo e especialistas na tomada de providências para o que está para acontecer.

3.3 Método

O processo metodológico consiste na aplicação dos 4 seguintes passos:

1. Coleta das informações e divisão dos dados de treinamento e teste;
2. Aprendizado de cinco modelos de séries temporais na base de treinamento (relatados nas Seções 3.3.1, 3.3.2, 3.3.3, 3.3.4 e 3.3.5);
3. Performance da previsão na base teste e avaliação de métricas de ajuste (MAE, MAPE, MASE, RMSE e R^2);
4. Reajuste dos modelos de melhor performance para toda a base de dados e previsão de 6 meses à frente.

Os cinco modelos de aprendizado consistem no ARIMA, ARIMA com erros *XGBoost*, ETS, regressão linear e *Prophet*. Estes são utilizados para previsões dos indicadores de crédito na base de dados na janela de teste, definida como o período a partir do início da pandemia no Brasil. O primeiro caso do coronavírus em território brasileiro foi identificado no final de fevereiro de 2020, e portanto, a janela especificada como período de pandemia, tem início em março de 2020 e se prolonga até data final disponibilizada, junho de 2021. A descrição dos dados é apresentada na Seção 3.4.

Seguidamente, o desempenho de cada modelo é estimado por meio de métricas de ajuste. E por fim, o melhor dos cinco é utilizado para previsão dos indicadores até o final do ano de 2021.

A implementação dos algoritmos é realizada no ambiente R de computação estatística (R Core Team, 2020).

3.3.1 ARIMA

Os modelos ARIMA (*Autoregressive Integrated Moving Average*) são amplamente utilizados em análises de séries temporais (BOX et al., 2015). Proposto por BOX; JENKINS, consiste na combinação de auto-regressão (AR), diferenciação e médias móveis (MA) da tendência. O modelo ARIMA (p,d,q) (componente auto-regressivo de ordem p), (d diferenciações), (componente de médias móveis de ordem q não-sazonal) é dado por:

$$\phi(B)(1 - B^d)y_t = c + \theta(B)\epsilon_t,$$

em que B representa o operador *backshift*, $\phi(\cdot)$ e $\theta(\cdot)$ são polinômios de ordem p e q , respectivamente, e ϵ_t representa um ruído branco com média zero e variância constante. O ARIMA $(p,d,q)(P,D,Q)$ sazonal, por sua vez, é formado pela inclusão de termos sazonais. Como notação, as letras minúsculas representam a parte não sazonal do modelo enquanto as letras maiúsculas são utilizadas para a parte sazonal do modelo. Este, por sua vez, é definido como:

$$\Phi(B^m)\phi(B)(1 - B^m)^D(1 - B)^d y_t = c + \Theta(B^m)\theta(B)\epsilon_t,$$

em que $\Phi(\cdot)$ e $\theta(\cdot)$ representam polinômios de ordem P (auto-regressivos) e Q (médias móveis), respectivamente, e D é a ordem de diferenciação sazonal.

O modelo ARIMA ideal é construído por meio de uma função de ajuste automático que combina testes de raiz unitária (não estacionaridade), minimização de correção da AIC para amostras de tamanho finito (AICc) e máximo da função de verossimilhança (MFV) para seleção dos parâmetros (HYNDMAN; ATHANASOPOULOS, 2018).

Uma importante característica para aplicação de modelos de regressão é a estacionaridade dos dados, quando a média e variação da série temporal são constantes ao longo do tempo. Com o ARIMA, a ordem de integração é o número de diferenças necessárias para tornar uma série não-estacionária em estacionária (FAVA, 2000); (PINDYCK; RUBINFELD, 2004).

3.3.2 ARIMA com erros *XGBoost*

Boosting é uma técnica que visa aprimorar a performance de um algoritmo de aprendizado através de uma combinação de vários algoritmos “fracos” (FREUND; SCHAPIRE et al., 1996). Atua portanto, de maneira sequencial, treinando o primeiro algoritmo nos dados originais, e os demais em dados enriquecidos com padrões mais complexos, classificados erroneamente em modelos anteriores (AVNIMELECH; INTRATOR, 1999). No caso do ARIMA, o algoritmo supervisionado ajustado tem como variável dependente os erros de um ARIMA previamente ajustado e como variáveis independentes as respectivas datas. Deste modo, tem-se que:

$$\begin{aligned}\hat{y}_i^{(0)} &= 0 \\ \hat{y}_i^{(1)} &= f_1(x_i) = \hat{y}_i^{(0)} + f_1(x_i) \\ \hat{y}_i^{(2)} &= f_1(x_i) + f_2(x_i) = \hat{y}_i^{(1)} + f_2(x_i) \\ &\dots\end{aligned}$$

$$\hat{y}_i^{(t)} = \sum_{k=1}^t f_k(x_i) = \hat{y}_i^{(t-1)} + f_t(x_i),$$

em que y_i são resíduos de um modelo ARIMA e os novos modelos são definidos a partir da otimização da função objetivo. A predição final é obtida a partir de uma combinação entre o modelo ARIMA e o ajuste dos resíduos através do *XGboost*.

3.3.3 ETS

Modelos de suavização exponencial realizam previsões com base em uma média ponderada de valores passados, com um decaimento exponencial no peso das observações mais antigas (HYNDMAN; ATHANASOPOULOS, 2018). HOLT estende o método de suavização exponencial simples para permitir o ajuste de séries com tendência. HOLT e WINTERS abrangem o modelo para capturar sazonalidade. O modelo de *Holt-Winters*, portanto, engloba a equação de previsão e três de suavização; para o *level* l_t , para a tendência b_t e para a sazonalidade s_t , com respectivos parâmetros α , β e γ , permitindo erros aditivos e multiplicativos (HYNDMAN; ATHANASOPOULOS, 2018).

Para ilustração, o modelo aditivo tem as seguintes previsões pontuais e equações de atualização:

$$\begin{aligned}\hat{y}_{t+h|t} &= l_t + hb_t + s_{t+h-m(k+1)} \\ l_t &= \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} + b_{t-1}) \\ b_t &= \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \\ s_t &= \gamma(y_t - l_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m},\end{aligned}$$

em que m denota a frequência da sazonalidade e k é o inteiro de $\frac{(h-1)}{m}$, garantindo o período de sazonalidade para a estimativa. Da mesma maneira, para o modelo multiplicativo segue que:

$$\hat{y}_{t+h|t} = (l_t + hb_t)s_{t+h-m(k+1)}$$

$$l_t = \alpha \frac{y_t}{s_{t-m}} + (1 - \alpha)(l_{t-1} + b_{t-1})$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1}$$

$$s_t = \gamma \frac{y_t}{l_{t-1} + b_{t-1}} + (1 - \gamma)s_{t-m}.$$

A classe de modelos desse tipo é denotada como ETS (*Error, Trend, Seasonal*). Diferentes configurações podem ser construídas já que o componente de tendência pode ser classificado em:

- *N*: Ausente;
- *A*: Aditivo;
- *M*: Multiplicativo;
- *A_d*: *Damped* aditivo;
- *M_d*: *Damped* Multiplicativo.

E a parte sazonal pode ser classificada em *N*, *A* e *M*. Algumas combinações são bastante conhecidas. A combinação (*N*, *N*) descreve o método de suavização exponencial simples (ou SES), (*A*, *N*) descreve o método linear de *Holt* e (*Ad*, *N*) descreve o método de tendência “amortecida” (*damped*). O método aditivo de *Holt-Winters* é dado por (*A*, *A*) e o método multiplicativo de *Holt-Winters* é dado por (*A*, *M*).

Ao contabilizar todas as combinações, o modelo ETS tem 15 modelos possíveis para erros aditivos e outros 15 para erros multiplicativos. O melhor modelo é escolhido automaticamente através de critérios de informação de Akaike e Akaike corrigido (AIC e AICc) e o critério de seleção Bayesiano de *Schwarz* (BIC) (HYNDMAN et al., 2002), (HYNDMAN; KHANDAKAR, 2008).

3.3.4 Regressão linear

O modelo de regressão linear (LM - *linear model*) assume uma relação linear no componente sistemático (JAMES et al., 2013). Em abordagens para séries

temporais é comum utilizar alguns preditores baseados no tempo t como componentes explicativos (HYNDMAN; ATHANASOPOULOS, 2018). Aqui, o tempo representa a tendência e as variáveis indicadoras para cada período representa a sazonalidade. Logo, o modelo é especificado como:

$$\hat{y}_t = \beta_0 + \beta_1 t + \sum_{k=2}^{12} \beta_k d_{k,t} + \epsilon_t,$$

em que t é o tempo e $d_{k,t}$ representa a variável indicadora mensal, de fevereiro a dezembro. O mês de referência (janeiro) é incorporado no intercepto. Para a estimativa dos parâmetros β 's utiliza-se o método de mínimos quadrados.

3.3.5 Prophet

Devido à escassez em se produzir previsões de alta qualidade, a equipe do *Core Data Science* do *Facebook* criou em meados de 2017, o *Prophet*, uma biblioteca em *Python* e *R*³. Já é bastante utilizada em aplicativos do *Facebook* e tem apresentado bom desempenho e auxílio para planejamento e definição de metas.

O *Prophet* é um procedimento automatizado e com muito pouco esforço manual para previsão de séries temporais em um modelo aditivo. As tendências não lineares são ajustadas a diversos tipos de sazonalidades — anual, semanal e diária, além de efeitos de feriados. É robusto para fortes efeitos sazonais, dados ausentes, mudanças na tendência e *outliers*.

Em sua estrutura, a série temporal é decomposta em três componentes: tendência, sazonalidade e feriado (TAYLOR; LETHAM, 2018). A estimação é descrita da seguinte maneira:

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

em que $g(t)$ representa a tendência, $s(t)$ a sazonalidade, $h(t)$ os feriados (incorporando o efeito de eventos irregulares) e ϵ_t representa desvios aleatórios não incluídos no modelo.

³ <<https://facebook.github.io/prophet/>>

O presente trabalho estima o modelo univariado das séries de crédito com crescimento linear de tendência e sazonalidades aditivas — a sazonalidade aditiva indica que a amplitude desta é constante ao longo do tempo, e assim, é adicionada à tendência. A tendência é estimada por uma curva linear, os efeitos sazonais são obtidos a partir de uma série de *Fourier* e o efeito de feriado é calculado por regularização (sem feriados diretos declarados), conforme descrito em (TAYLOR; LETHAM, 2018).

3.4 Dados

O SGS⁴ contém valores mensais dos principais indicadores de crédito das operações do Sistema Financeiro Nacional (SFN) do Brasil . As séries temporais compreendem o período de janeiro de 2013 a junho de 2021. De acordo com o Glossário de crédito do BCB, as definições para saldo, prazo, ICC, *spread*, taxa de juros e inadimplência são:⁵

- Saldo da carteira ativa: Corresponde ao somatório do saldo devedor dos contratos de crédito em final de mês. Inclui as novas concessões liberadas no mês e a apropriação de juros pró-rata das operações de empréstimos e financiamentos;
- Prazo médio da carteira: Média dos prazos de cada pagamento (em meses) ponderada pelo respectivo valor. No caso das operações em atraso, são consideradas somente as carteiras com atraso até noventa dias, cujo prazo considerado na apuração é de 1 (um) dia;
- Indicador de Custo de Crédito (ICC): Custo médio das operações de crédito que integram a carteira de empréstimos, financiamentos e arrendamento mercantil das instituições financeiras integrantes do SFN. Inclui todas as operações em aberto classificadas no ativo circulante, independente da data de contratação do crédito;

⁴ <<https://www3.bcb.gov.br/sgspub/localizarseries/localizarSeries.do?method=prepararTelaLocalizarSeries>>

⁵ <https://www.bcb.gov.br/content/estatisticas/docs_estatisticasmonetariascredito/glossariocredito.pdf>

- *Spread* médio: Refere-se à diferença entre a taxa média de juros e o custo de captação estimado.
- Taxa média de juros: Média das taxas de juros das concessões, ponderada pelos respectivos valores desembolsados;
- Inadimplência da carteira: Somatório do saldo das operações de crédito com atraso acima de 90 dias e não baixado para prejuízo, dividido pelo saldo total de crédito da carteira.

Cada indicador tem sua forma de mensuração. O saldo é em milhões de reais, o prazo em meses, o ICC em percentual ao ano, o *spread* em pontos percentuais (diferença entre as porcentagens do ICC e custo de captação), a taxa de juros em percentual ao mês e a inadimplência em percentual.

Na Tabela 9 tem-se os valores para os indicadores de crédito no período pandemia. Como relatado na Seção 3.3, o início da pandemia no Brasil é a partir de março de 2020, e o último mês de análise é junho de 2021.

Tabela 9 – Valores dos indicadores no período pandemia

Data	Saldo	Prazo	ICC	<i>Spread</i>	Juros	Inadimplência
03/2020	3,867,526	51.79	20.06	14.35	1.72	3.18
04/2020	3,879,558	52.35	19.72	14.07	1.63	3.29
05/2020	3,907,716	52.76	19.17	13.63	1.58	3.25
06/2020	3,926,344	53.09	18.66	13.27	1.49	2.89
07/2020	3,963,103	53.47	18.21	12.93	1.47	2.77
08/2020	4,029,486	55.44	17.80	12.62	1.43	2.65
09/2020	4,087,047	55.93	17.37	12.27	1.39	2.43
10/2020	4,113,345	55.12	17.22	12.14	1.43	2.36
11/2020	4,160,400	55.38	17.04	12.02	1.43	2.23
12/2020	4,172,356	55.07	16.76	11.81	1.42	2.12
01/2021	4,157,875	55.15	17.03	12.08	1.54	2.15
02/2021	4,149,612	54.82	17.19	12.25	1.51	2.24
03/2021	4,174,393	54.55	17.13	12.16	1.53	2.17
04/2021	4,183,795	54.79	17.20	12.17	1.56	2.22
05/2021	4,198,331	54.92	17.23	12.15	1.52	2.37
06/2021	4,213,907	55.01	17.31	12.16	1.52	2.30

É fácil notar que o saldo e o prazo terminaram em patamares maiores do que os iniciados em março de 2020. No caso do ICC, *spread*, juros e inadimplência, o padrão é o oposto; no final do período de análise, os valores são consideravelmente menores do que no início da pandemia (Observe a Tabela 9).

A fim de ilustração, as Figuras 13, 14, 15, 16, 17 e 18, trazem uma visão histórica desde 2013 com valores em destaque para o início da pandemia, picos de queda e o último mês analisado.

Figura 13 – Série temporal do saldo total da carteira ativa




Figura 14 – Série temporal do prazo médio da carteira




Figura 15 – Série temporal do ICC (percentual ao mês)




Figura 16 – Série temporal do spread




Figura 17 – Série temporal da taxa de juros





Figura 18 – Série temporal da inadimplência



As séries do saldo (Figura 13) e prazo (Figura 14) apresentam cenário de crescimento durante o período da pandemia. Enquanto que o percentual do ICC (Figura 15), *spread* (Figura 16), taxa de juros (Figura 17) e inadimplência (Figura 18) terminam em queda no ano de 2020, com retorno de crescimento nos primeiros meses de 2021.

O saldo da carteira ativa determina a quantidade de reais em milhões das operações de crédito no SFN. A fim de expurgar o efeito inflacionário dos preços, os valores foram deflacionados pelo Índice de Preços ao Consumidor Amplo (IPCA)⁶. A data-base do índice foi a de junho de 2021, com o objetivo de trazer uma percepção dos valores hoje. Em março de 2020 o saldo é de R\$3.8 trilhões, atingindo 15 meses depois a quantidade de R\$4.2 trilhões. O único mês em que se observa uma leve queda durante o período da pandemia é em fevereiro de 2021, com o valor de R\$4.1 trilhões (Observe Figura 13).

O prazo médio da carteira mensura o tempo médio de duração dos em-

⁶ Série histórica do IPCA geral disponível no Ipeadata: <<http://www.ipeadata.gov.br>>

préstimos. No começo da pandemia a série do prazo (Figura 14) aponta para 51.7 meses em média e atinge um pico de 55.9 em setembro de 2020. Em junho de 2021, o valor é de 55. Ou seja, Um aumento de 6% comparado a março de 2020.

O ICC é um indicador para o custo de crédito brasileiro. A série do ICC (Figura 15) começa num patamar de 20% a.a. em março de 2020, atingindo 16.7% a.a. em dezembro de 2020 — o menor percentual desde 2013. Em junho de 2021, o valor volta à estabilidade, e se concentra em torno de 17.3% a.a..

O *spread* do ICC é um dos componentes do ICC e quanto maior, maior tende a ser o custo do crédito. Este indicador permite identificar os fatores que determinam o custo do crédito para os tomadores, deixando de fora os efeitos das condições de mercado relacionadas ao custo de captação de recursos dos bancos. A série do *spread* (Figura 16) começa no nível de 14.3 p.p. em março de 2020 e atinge 11.8 p.p.. A partir disso, volta a crescer, e em junho 2021 o valor é de 12.1 p.p..

A taxa de juros é o valor que o tomador deve pagar ao proprietário do capital emprestado, pois o segundo abre mão da liquidez imediata em favor de rendimentos futuros. Esta (Figura 17) apresenta queda em quase todos os momentos da pandemia. No início de 2020 o percentual médio é de 1.7 a.m. e termina em um patamar de 1.5 a.m. no final da série. Em setembro de 2020 atinge-se o menor valor da série histórica: 1.3% a.m.. Aqui, o padrão se repete: os percentuais sofrem aumentos em 2021, mas ainda continuam sendo mais baixos do que 2020.

A inadimplência mede o percentual de pessoas e empresas em estado de 90 dias de atraso em suas dívidas. Este dado econômico é um dos mais importantes, pois determina o risco da operação de crédito. Ao observar o período pandemia, a série da inadimplência (Figura 18) tem pico percentual em abril de 2020, com o valor de 3.2%. Dali adiante, este indicador sofre uma queda acentuada, a chegar em 2.1% em dezembro de 2020 — menor valor da série histórica. Ao final da série, com um retorno leve de crescimento, 2.3% das operações de crédito estão em estado de inadimplência.

Em resumo, nas séries do saldo e prazo, o cenário é de crescimento durante todo o período da pandemia. Já os indicadores de crédito percentuais —

ICC, *spread*, juros e inadimplência; têm comportamento muito similar. Como são componentes determinantes do custo do crédito no Brasil, medido pelo ICC, são correlacionados de certa forma. Estes terminam em queda no ano de 2020, com um retorno de crescimento nos primeiros meses de 2021.

3.5 Resultados

Nesta Seção, apresentam-se as estimativas na base teste, as métricas de acurácia, os modelos selecionados e a previsões de um horizonte de 6 meses à frente, para completar o ano de 2021.

3.5.1 Previsões na base teste

As Figuras 19, 20, 21, 22, 23 e 24 demonstram os resultados gráficos das estimativas na base teste para cada indicador de crédito. As informações de 2013 até fevereiro de 2020 são utilizadas como treinamento. Neste passo, é possível averiguar o comportamento esperado das séries caso não existisse a crise da pandemia.

Figura 19 – Saldo - Previsão período pandemia

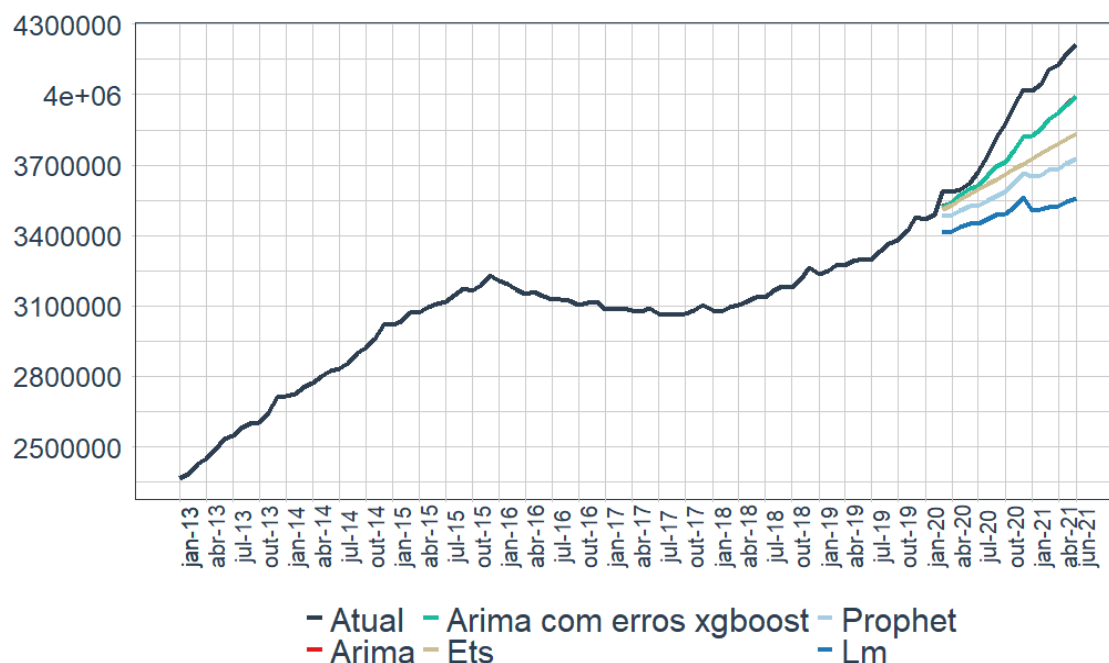


Figura 20 – Prazo - Previsão período pandemia




Figura 21 – ICC - Previsão período pandemia




Figura 22 – Spread - Previsão período pandemia




Figura 23 – Taxa de juros - Previsão período pandemia





Figura 24 – Inadimplência - Previsão período pandemia



- Saldo (Figura 19)⁷: Os modelos esperavam crescimento em 2020 em relação a 2019. Ainda assim, ao comparar com o que realmente aconteceu, todos os modelos subestimaram os valores do saldo para o período da pandemia. O ARIMA e ARIMA com erros *XGBoost* apresentam as curvas mais próximas dos valores observados.
- Prazo (Figura 20): Neste caso, o modelo LM superestimou os meses médios de duração das carteiras de crédito. Os demais modelos apresentam comportamento muito similar, uma previsão de estabilidade e um pico em outubro de 2020, seguindo o padrão do ano anterior.
- ICC (Figura 21): Os modelos ARIMA e ETS estimaram uma redução percentual em 2020 em relação a 2019, o *Prophet*, uma estabilidade e o LM, um aumento. Ao comparar com o que realmente aconteceu, todos os modelos superestimaram os valores do ICC para o período da pandemia. Em

⁷ Série do saldo não deflacionada.

contrapartida, parecem concordar com o comportamento de variação entre os meses.

- *Spread* (Figura 22): Os modelos LM e *Prophet* apontavam para um crescimento durante o período da pandemia. Ambos ARIMA e ETS esperavam comportamento similar ao ano de 2019. Mas o que acontece de fato, é um decréscimo brusco que só é interrompido no início de 2021.
- Taxa de juros (Figura 23): As previsões do ARIMA e ETS têm valores similares e são as mais próximas do cenário real. Já o *Prophet* aponta para uma queda menos acentuada. Os modelos ARIMA com erros *XGBoost* e LM mostram percentuais mais altos e distantes dos valores observados.
- Inadimplência (Figura 24): Aqui, os modelos apresentaram os mesmos comportamentos, onde *Prophet* previu os valores mais baixos e o ARIMA com erros *XGBoost*, os valores mais altos. Todavia, nenhum deles esperavam uma queda tão significativa como a que ocorreu em 2020.

3.5.2 Métricas de acurácia

As métricas de acurácia são informações importantes para comparar os modelos de séries temporais e se representam um bom ajuste aos dados. Todas baseiam-se no cálculo do erro de previsão de um passo à frente no tempo t .

Os indicadores mensurados são: erro médio absoluto (MAE), média percentual absoluta do erro (MAPE), erro médio absoluto escalado (MASE) e raiz do erro quadrático médio (RMSE). Estes indicadores são baseados nos erros dos modelos e portanto, quanto menor, melhor é o modelo. Também calcula-se o R^2 , que indica o grau de variação explicada pelo modelo (maiores valores indicam um melhor ajuste).

Tabela 10 – Métricas de Acurácia dos indicadores por modelo

Indicador	Modelo	MAE	MAPE	MASE	RMSE	R^2
Saldo	ARIMA	139,220	3.4	3.2	157,503	0.9
	ARIMA <i>XGboost</i>	139,682	3.5	3.2	157,503	0.9
	ETS	213,142	5.3	5.0	245,419	0.9
	<i>Prophet</i>	284,243	7.1	6.7	316,736	0.9
	LM	393,624	9.9	9.2	413,106	0.8
Prazo	ARIMA	1.7	3.2	4.0	2.0	0.0
	ARIMA <i>XGboost</i>	1.5	2.8	3.4	1.7	0.0
	ETS	1.2	2.2	2.7	1.3	0.5
	<i>Prophet</i>	1.3	2.4	2.9	1.4	0.4
	LM	3.2	6.0	7.3	3.3	0.5
ICC	ARIMA	1.4	8.1	5.3	1.5	0.8
	ARIMA <i>XGboost</i>	1.8	10.3	6.8	1.9	0.8
	ETS	1.5	9.1	5.9	1.7	0.8
	<i>Prophet</i>	2.8	16.4	10.	3.0	0.1
	LM	4.3	24.6	16.3	4.4	0.0
<i>Spread</i>	ARIMA	1.5	12.4	7.4	1.6	0.7
	ARIMA <i>XGboost</i>	1.9	15.6	9.3	2.0	0.7
	ETS	1.7	13.9	8.2	1.8	0.3
	<i>Prophet</i>	2.6	21.4	12.7	2.8	0.3
	LM	2.5	20.8	12.4	2.7	0.1
Taxa de juros	ARIMA	0.1	6.8	2.4	0.1	0.1
	ARIMA <i>XGboost</i>	0.4	28.7	10.4	0.4	0.1
	ETS	0.1	6.1	2.2	0.1	0.1
	<i>Prophet</i>	0.2	16.3	5.8	0.2	0.3
	LM	0.5	35.6	12.8	0.5	0.1
Inadimplência	ARIMA	0.6	27.7	5.5	0.7	0.2
	ARIMA <i>XGboost</i>	0.9	42.2	8.5	1.1	0.2
	ETS	0.6	26.9	5.3	0.7	0.0
	<i>Prophet</i>	0.5	21.9	4.3	0.5	0.1
	LM	0.7	32.1	6.4	0.8	0.1

- Modelos ARIMA e ARIMA *XGBoost*: possuem ajustes semelhantes, mas o ARIMA tradicional apresenta métricas, no geral, um pouco melhores. Este último tem o menor erro para os indicadores do saldo, ICC e *spread*. Os modelos ARIMA estimam bem quando há autocorrelação nos dados, ou seja, os dados anteriores explicam os dados presentes.

- Modelo ETS: apresenta o melhor ajuste para o ICC, $R^2 = 0.84$. Este modelo também tem os menores valores de erro para a taxa de juros e prazo. A explicação para isso é que os modelos ETS não são estacionários e modelam explicitamente componentes tendência e/ou sazonalidade nos dados com suavização exponencial. Componentes estes que estão evidentes em ambas as séries.
- Modelo *Prophet*: estima bem a inadimplência em questão dos menores erros. E apresenta o melhor R^2 para taxa de juros (0.34).
- Modelo LM: não parece se ajustar bem a nenhum dos indicadores. No caso do prazo, possui o melhor R^2 . A justificativa para isso é que a série de prazo tem uma tendência linear, sem aparentes pontos de mudança.

3.5.3 Parâmetros dos modelos

Aqui, apresentam-se os resultados dos parâmetros dos modelos escolhidos para cada indicador de acordo com os menores valores nas métricas dos erros de previsões. Os modelos ARIMA são modelos ateóricos, e então a abordagem usual para interpretar os coeficientes de regressão estimados não é realmente transportada para a modelagem ARIMA.

1) Saldo da carteira ativa: O modelo ARIMA possui dois componentes autorregressivos, duas diferenciações simples, 1 componente de médias móveis da tendência e 2 componentes autorregressivos sazonais.

Tabela 11 – Saldo: ARIMA(2,2,1)(2,0,0)

Componente	AR1	AR2	MA1	SAR4	SAR2
Coefficiente	-0.26	-0.30	-0.43	0.51	0.28
Desvio Padrão	0.21	0.15	0.21	0.10	0.11

2) Prazo da carteira: Este modelo é definido como de *Holt damped* com erros multiplicativos. A tendência é aditiva com *damped* — permite mudança ao longo do tempo com um parâmetro de “amortecimento” ϕ ; e não há a presença de sazonalidade.

Tabela 12 – Prazo: ETS(M, Ad,N)

	α	0.66
Parâmetros suavização	β	0.0001
	ϕ	0.97
	l	37.86
Estados Iniciais	b	0.41
	Sigma	0.01

3) ICC: O modelo ARIMA possui uma diferenciação simples, 3 componentes autorregressivos da tendência e 2 sazonais.

Tabela 13 – ICC: ARIMA(3,1,0)(2,0,0)

Componente	AR1	AR2	AR3	SAR1	SAR2
Coefficiente	0.43	0.18	0.18	0.44	0.36
Desvio Padrão	0.10	0.12	0.11	0.10	0.11

4) *Spread*: O modelo ARIMA possui uma diferenciação simples, um componente autorregressivo da tendência e 2 sazonais.

Tabela 14 – *Spread*: ARIMA(1,1,1)(2,0,0)

Componente	AR1	MA1	SAR1	SAR2
Coefficiente	0.85	-0.50	0.45	0.35
Desvio Padrão	0.08	0.13	0.10	0.12

5) Taxa de juros: Este modelo é definido como de *Holt-Winters* aditivo com erros aditivos. Os pequenos valores de β e γ significam que a inclinação e os componentes sazonais mudam muito pouco com o tempo.

Tabela 15 – Taxa de juros: ETS(A,A,A)

Parâmetros de suavização	α	0.62					
	β	0.17					
	γ	0.02					
Estados Iniciais	l	1.53					
	b	0.02					
	s	-0.05	0.003	0.003	-0.02	0.0004	0.0005
		-0.01	-0.004	0.008	0.02	0.03	0.01
Sigma	0.001						

6) Inadimplência: As configurações do modelo *Prophet* foram as seguintes: 25 pontos de mudança (*default*), alcance do ponto de mudança igual a 0.8 (ajusta a flexibilidade da tendência e é limitado a 80% dados iniciais da amostra), escala a priori de ponto de mudança igual a 0.05 e escala a priori de sazonalidade e feriados igual a 10. As escalas a priori definem a força do componente no modelo.

3.5.4 Reajustando para o conjunto de dados completo e previsão 2021

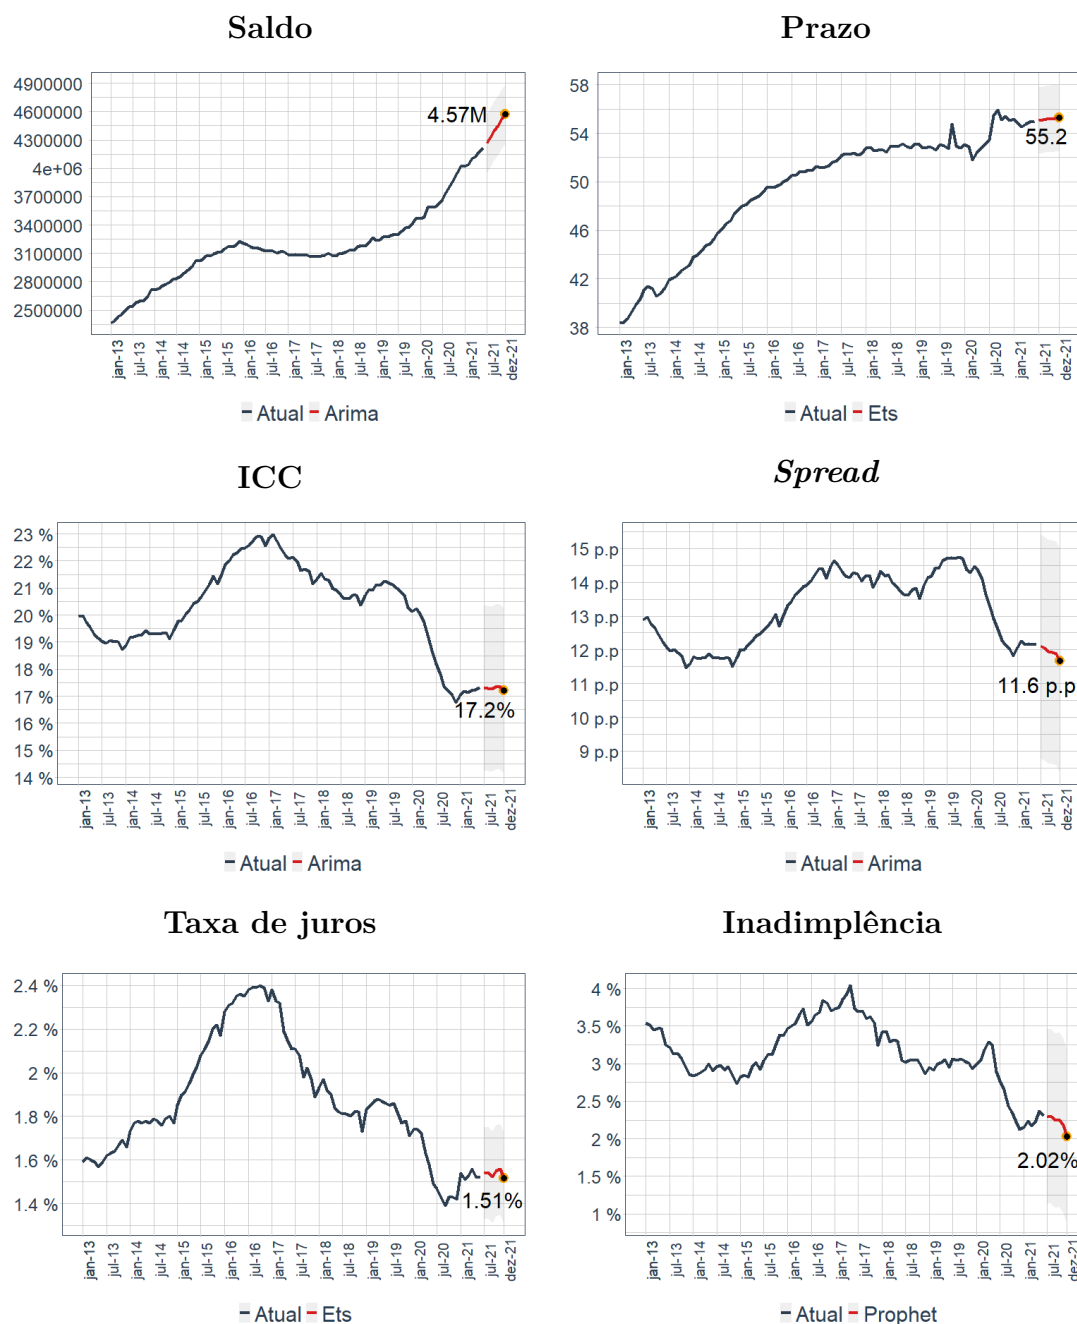
Para a previsão de seis meses à frente, o modelo com os menores erros e um bom ajuste é escolhido para cada indicador e seguidamente, reajustado à base de dados completa. Aqui as configurações dos modelos ARIMA e *ETS* são modificados, já que possuem mais informações para calibração dos parâmetros.

Para as séries do saldo, ICC e *spread*, o modelo ARIMA foi o que apresentou os menores erros. Para a taxa de juros e o prazo foi o modelo ETS. Por fim, para a inadimplência, o *Prophet* teve o melhor desempenho.

No reajuste para a previsão do segundo semestre de 2021, alguns dos modelos foram atualizados. Na série do saldo, o modelo foi alterado para as seguintes ordens em cada componente do ARIMA: auto-regressivo (0), diferenciação (2) e médias móveis (1), auto-regressivo sazonal (0), diferenciação sazonal (0) e médias móveis sazonais (2), ou seja, ARIMA(0,2,1)(0,0,2). O modelo do ICC foi atualizado para um ARIMA(2,2,0)(2,0,0). E a taxa de juros, por sua vez, havia ajustado um modelo de suavização exponencial com erro, tendência e sazonalidade aditivos; para as previsões à frente, o modelo ajustou-se para erros multiplicativos, tendência aditiva com *damped* e sazonalidade multiplicativa.

A Figura 25 apresenta os valores previstos para os indicadores.

Figura 25 – Previsões das séries de crédito - 2021



Avaliando os resultados da Figura 25, o ARIMA para saldo espera ainda mais crescimento ao longo do ano de 2021, R\$4.5 trilhões em dezembro. Na série do prazo, o modelo ETS aponta para um leve aumento ao longo dos meses, atingindo 55.2 meses em média no final do ano. O ARIMA para o ICC aponta para um percentual estável ao longo do ano de 2021 — em dezembro, uma previsão de 17.2% a.a.. Para o *spread*, a situação prevista é de leve decréscimo nesse último semestre de 2021, chegando a 11.6 p.p.. Para a taxa de juros o cenário é similar ao do ICC, estabilidade. Neste caso, o modelo ETS aponta um percentual final da taxa de juros de 1.51% a.m.. Para a inadimplência, o *Prophet* aponta para um comportamento de mais reduções, finalizando em 2.02% o ano de 2021.

A Tabela 16 apresenta os valores por indicador e mês.

Tabela 16 – Previsões 2021 dos indicadores de crédito

Data	Saldo (milhões)	Prazo	ICC	<i>Spread</i>	Taxa de Juros	Inadimplência
jul/21	4,263,316	55.05	17.29	12.10	1.53	2.30
ago/21	4,324,455	55.10	17.29	12.04	1.54	2.29
set/21	4,392,364	55.15	17.27	11.93	1.52	2.24
out/21	4,451,350	55.19	17.33	11.92	1.55	2.25
nov/21	4,519,487	55.24	17.37	11.89	1.55	2.17
dez/21	4,574,976	55.28	17.22	11.67	1.51	2.02

3.6 Discussão

De acordo com a análise dos dados dos indicadores de crédito brasileiro durante a pandemia da Covid-19, o saldo total de empréstimos no SFN apresenta crescimento ininterrupto, os prazos foram prolongados, o ICC, *spread*, a taxa de juros e a inadimplência sofreram grandes reduções.

Os modelos de séries temporais esperavam um aumento singular para o saldo total da carteira em comparação a 2019, mas não o crescimento íngreme que ocorreu ao longo da pandemia — o que demonstra o incentivo ao crédito durante esse período para as empresas e famílias (Seção 3.5.1). O mesmo acontece para o prazo médio, no geral, os modelos esperavam uma estabilidade, ao invés de um alongamento dos prazos.

Para o caso dos indicadores do ICC, *spread*, juros e inadimplência, e devido à correlação entre eles, os modelos se comportam de forma similar: não esperavam quedas tão bruscas como as que aconteceram.

Para o ICC, o esperado era decrescimento, mas bem mais leve. Para o *spread* e a inadimplência o cenário era de estabilidade, semelhante ao ano de 2019. Para a taxa de juros, havia um cenário esperado de decrescimento constante no decurso da pandemia, seguindo o comportamento que vem ocorrendo desde 2017. Os modelos ARIMA e ETS previram bem próximo do real, mas não anteciparam o pico de queda que ocorreu em setembro de 2020.

Os fatores de estímulo de crédito tradicionais, como a queda na taxa básica de juros (de 4,5% para 2% ao ano) e a redução do compulsório (reserva obrigatória recolhida dos depósitos bancários) foram importantes para que o acesso ao crédito não encolhesse. A redução da Selic faz com que os bancos aumentem a quantidade de novos empréstimos e diminuam as taxas de juros (COELHO; MELLO; GARCIA, 2010), (BEZERRA; LIMA; SILVA, 2016). Além disso, no primeiro semestre de 2020, diversas medidas de apoio do governo e das IF's foram lançadas.

O Conselho Monetário Nacional estabeleceu critérios temporários para a caracterização das reestruturações de empréstimos, para fins de gerenciamento de risco de crédito.⁸ As repactuações de dívidas foi uma das primeiras medidas adotadas pelo BCB, que, na prática, incentivou as IF's a estender os prazos de pagamentos aos devedores. Desde o início da crise, cerca de um terço da carteira de crédito sofreu repactuação.⁹

Mesmo que o desemprego tenha aumentado (14.7% no primeiro trimestre de 2021, valor recorde desde 2012)¹⁰. A incerteza de uma renda futura e a chegada de um auxílio emergencial, o AE¹¹, podem ser possíveis explicações para que as famílias repensassem e revisassem gastos, priorizando o pagamento das dívidas e bens essenciais. O AE foi pago em cinco parcelas de R\$600 ou R\$1.2 mil para

⁸ Resolução 4.782, de 16 de março de 2020, prorrogada pela Resolução 4.856, de 24 de setembro de 2020.

⁹ <<https://www.bcb.gov.br/content/publicacoes/ref/202104/RELESTAB202104-refPub.pdf>>.

¹⁰ <<https://www.ibge.gov.br/explica/desemprego.php>>.

¹¹ Lei nº 13.982, de 02 de abril de 2020.

mães chefes de família monoparental e, depois, estendido até 31 de dezembro de 2020 em até quatro parcelas de R\$300 ou R\$600 cada. Sendo assim, esse auxílio teria reposto as perdas de renda do trabalhador e combinado com flexibilizações de prazo por parte das IF's, fez com que a inadimplência apresentasse decréscimo durante os primeiros meses da pandemia.

Já na visão empresas, programas como o Pronampe¹², uma linha de financiamento exclusiva de apoio às micro e pequenas empresas, o PEAC¹³, PESE¹⁴ e o BNDES Crédito Pequenas Empresas estimularam a roda do crédito a girar novamente.

Esses programas garantem crédito a um segmento com dificuldades históricas para obtê-lo, com juros menores e prazos mais dilatados. Durante a primeira onda da pandemia, as IF's começaram a ser muito criteriosos na análise e liberação do crédito. Com o Pronampe, por exemplo, os empréstimos são facilitados, já que as IF's emprestam dinheiro a empresários tendo como garantia recursos de um fundo público. Em contrapartida, as empresas beneficiadas assumem o compromisso de preservar o número de funcionários. Diante do fato que, milhares de empresas que nunca tiveram acesso ao crédito passaram a ser incluídas no SFN, tem-se um efeito positivo no saldo da carteira ativa, onde o decréscimo era o padrão desde 2016.

Essas medidas, no geral, são refletidas nos baixos níveis dos indicadores de inadimplência e taxa de juros e no crescimento do saldo da carteira e prazo médio durante o período da pandemia. E isso responde a hipótese de que, os fatores exógenos como medidas emergências e ações do governo e bancos, de fato, afetam o comportamento dos indicadores do mercado de crédito durante a pandemia.

No último mês de análise, junho de 2021, a maioria dos programas e auxílios chegou ao fim, como no caso dos programas no BNDES; ou foram reduzidos, como no caso do AE; ou modificados, como no caso do Pronampe. Aqui, os indicadores do ICC, *spread*, taxa de juros e inadimplência voltam a crescer, no caso, mais para

¹² Programa de Apoio às Microempresas e Empresas de Pequeno Porte: Lei nº 13.999, de 18 de maio de 2020.

¹³ Programa Emergencial de Acesso ao Crédito: Lei nº 14.042, de 19 de agosto de 2020.

¹⁴ Programa Emergencial de Suporte a Empregos: Lei nº 14.042, de 19 de agosto de 2020.

o sentido de estabilidade, como estimado pelos modelos de previsão (Figura 25).

As primeiras versões do Pronampe terminaram no fim em dezembro de 2020. Em junho de 2021, seis meses sem essa linha de crédito, o governo sanciona e torna permanente o novo Pronampe, que conta com menos recursos em relação ao anterior: tem juros mais altos (1,25% a 6% ao ano mais a taxa Selic), prazo mais dilatados para carência (de 8 para 11 meses) e pagamento (36 meses para 48 meses). Portanto, esse novo programa pode influenciar no aumento do saldo, da taxa de juros e dos prazos nesse finalzinho de 2021.

Além disso, o AE de 2021 começou a ser pago em 6 de abril e é limitado a uma pessoa por família. São quatro parcelas de R\$ 150 (para famílias de uma só pessoa), R\$250 (para famílias de duas ou mais pessoas) ou R\$375 (para mães chefes de família monoparental). Outro ponto é que a grande maioria (84%) das operações repactuadas já saiu do período de carência e voltou ao fluxo normal de pagamentos, o que deve contribuir no equilíbrio e estabilidade dos prazos e geral.

De toda forma, a expectativa de retomada da economia à medida que a vacinação avança no país, o índice de desemprego, a inflação e a incerteza futura podem exercer grande influência no comportamento dos indicadores de crédito, e mais uma vez, o futuro é incerto.

3.7 Conclusão

No final de 2019, a economia brasileira apresentava um certo otimismo, com reformas aprovadas, contas públicas e inflação sob controle e uma taxa básica de juros que alcançou o menor patamar da história.

Com a chegada da pandemia da Covid-19, todas as expectativas ficaram para trás. O isolamento necessário para conter a propagação do vírus fechou escolas, comércios, empresas. A paralisação da atividade econômica fez subir o desemprego e o dólar e levou a inflação ao menor patamar em 22 anos.

Este estudo proporciona um quadro atual do cenário de crédito no Brasil por meio da estimação do comportamento dos principais indicadores de crédito brasileiro no período da pandemia. Os modelos de séries temporais não esperavam

valores tão baixos para o ICC, *spread*, taxas de juros e, a destacar, pela inadimplência. Também não esperavam a expansão acentuada do saldo total, assim como, o aumento da duração média dos empréstimos.

Apesar da alta do desemprego e da baixa poupança precaucional no início da crise, os efeitos sobre a inadimplência das famílias e empresas durante o ano de 2020 são menos intensos do que se poderia prever. O ICC, *spread*, taxas de juros e inadimplência estão mais baixos — num dos menores patamares desde 2013; os prazos estão prolongados; e o saldo total da carteira de crédito em crescimento contínuo.

Como hipótese levantada, as ações do governo e IF's teriam mudado sim, e de forma positiva, a tendência dos indicadores de crédito brasileiro, assim como encontrado em (NARAYAN; PHAN; LIU, 2020). Diversas medidas emergenciais foram tomadas com o intuito de mitigar o impacto negativo causado pela inesperada pandemia (JORDÀ; SINGH; TAYLOR, 2020). O AE, os programas de incentivo ao crédito e a flexibilização dos prazos e taxa de juros, fizeram com que a demanda de crédito continuasse a crescer e a inadimplência não aumentasse, algo jamais imaginado.

Sem um fim para a pandemia à vista, as previsões para 2021 apontam para uma taxa de juros e ICC em estabilidade, *spread* e inadimplência ainda em decréscimo, saldo e prazo ampliados. Mais uma vez, essas suposições podem encontrar dificuldades de serem concretizadas. A extensão final dos danos econômicos e sociais da Covid-19 está para ser conhecida.

Como limitação metodológica desse estudo, algumas melhorias podem ser sugeridas, sendo essas: transformações na variável do tempo, como o seu quadrado; acréscimo de variáveis explicativas relevantes do mercado de crédito; estimação na base teste por janelas móveis; combinação de vários modelos por meio do método *ensemble* para previsão.

Referências

AGIWAL, V.; KUMAR, J.; SHANGODOYIN, K. A bayesian inference of multiple structural breaks in mean and error variance in panel ar (1) model. *Statistics in Transition New Series*, v. 19, 03 2018. Citado 2 vezes nas páginas 20 e 21.

ANDREWS, D. Tests for parameter instability and structural change with unknown change point. *Econometrica*, v. 61, p. 821–856, 1993. Citado na página 19.

ANDREWS, D.; DOAN, T.; PLOBERGER, W. Optimal tests when a nuisance parameter is present only under the alternative. *Econometrica*, v. 62, p. 1383–1414, 02 1994. Citado na página 19.

AVNIMELECH, R.; INTRATOR, N. Boosting regression estimators. *Neural computation*, MIT Press, v. 11, n. 2, p. 499–520, 1999. Citado na página 65.

BAI, J. Common breaks in means and variances for panel data. *Journal of Econometrics*, v. 157, p. 78–92, 2010. Citado na página 20.

BAI, J.; PERRON, P. Estimating and testing linear models with multiple structural changes. *Econometrica*, v. 66, p. 47–78, 1995. Citado na página 43.

BAI, J.; PERRON, P. Computation and analysis of multiple structural-change. *Journal of Applied Econometrics*, v. 18, 01 2003. Citado 3 vezes nas páginas 43, 50 e 52.

BARBOZA, R. Taxa de juros e mecanismos de transmissão da política monetária no brasil. *Revista de Economia Política*, v. 35, p. 133–155, 03 2015. Citado na página 42.

BECK, E. Are consumers more interested in financing incentives or price reductions. In: . [S.l.: s.n.], 2003. Citado na página 43.

BECK, T.; KEIL, J. Are banks catching corona? effects of covid on lending in the u.s. *CEPR Discussion Paper 15869*, 03 2021. Citado na página 62.

BEZERRA, J.; LIMA, R.; SILVA, I. A study on bank credit channel in brazil: The approach of impulse response functions matching. *Economia Aplicada*, v. 20, p. 245, 06 2016. Citado 2 vezes nas páginas 45 e 87.

- BISWAS, D. Understanding the economic growth of west bengal: A multiple structural breaks approach. *Indian Journal of Human Development*, v. 14, n. 1, p. 62–75, 2020. Disponível em: <<https://EconPapers.repec.org/RePEc:sae:inddev:v:14:y:2020:i:1:p:62-75>>. Citado na página 50.
- BOGAN, V.; TURVEY, C.; SALAZAR, G. The elasticity of demand for microcredit: Evidence from latin america. *Development Policy Review*, v. 33, p. 725–757, 11 2015. Citado na página 44.
- BONOMO, M.; MARTINS, B. *The Impact of Government-Driven Loans in the Monetary Transmission Mechanism: what can we learn from firm-level data?* [S.l.], 2016. Disponível em: <<https://ideas.repec.org/p/bcb/wpaper/419.html>>. Citado na página 42.
- BOX, G.; JENKINS, G. Control. *Halden-Day, San Francisco*, 1970. Citado na página 64.
- BOX, G. E. et al. *Time series analysis: forecasting and control*. [S.l.]: John Wiley & Sons, 2015. Citado na página 64.
- BROCK, P. L.; SUAREZ, L. R. Understanding the behavior of bank spreads in latin america. *Journal of development Economics*, Elsevier, v. 63, n. 1, p. 113–134, 2000. Citado na página 15.
- BROWN, R.; DURBIN, J.; EVANS, J. M. Techniques for testing the constancy of regression relationships over time. *Journal of the royal statistical society series b-methodological*, v. 37, p. 149–163, 1975. Citado 2 vezes nas páginas 13 e 18.
- BYRD, R. et al. A limited memory algorithm for bound constrained optimization. *SIAM J. Sci. Comput.*, v. 16, p. 1190–1208, 1995. Citado na página 27.
- CAPPELLI, C. et al. Multiple breaks detection in financial interval-valued time series. *Expert Systems with Applications*, v. 164, p. 113775, 2021. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417420305996>>. Citado na página 22.
- CHATURVEDI, A.; KUMAR, J. Bayesian unit root test for time series models with structural breaks. *American Journal of Mathematical and Management Sciences*, Taylor Francis, v. 27, n. 1-2, p. 243–268, 2007. Disponível em: <<https://doi.org/10.1080/01966324.2007.10737699>>. Citado na página 20.
- CHAURASIA, V.; PAL, S. Application of machine learning time series analysis for prediction covid-19 pandemic. *Research on Biomedical Engineering*, 10 2020. Citado na página 63.

CHOW, G. Tests of equality between sets of coefficients in two linear regressions (econometrics voi 28. In: . [S.l.: s.n.], 1960. Citado na página 18.

CHU, C.-S. J.; HORNIK, K.; KUAN, C.-M. Mosum tests for parameter constancy. *Biometrika*, v. 82, p. 603–617, 1995. Citado na página 19.

CHU, C.-S. J.; HORNIK, K.; KUAN, C.-M. The moving-estimates test for parameter stability. *Econometric Theory*, v. 11, p. 699–720, 1995. Citado na página 19.

COELHO, C.; MELLO, J.; GARCIA, M. Identifying the bank lending channel in brazil through data frequency. *Economía: Journal of the Latin American and Caribbean Economic Association*, v. 10, 01 2010. Citado 2 vezes nas páginas 44 e 87.

CRIBARI-NETO, F. Asymptotic inference under heteroskedasticity of unknown form. *Computational Statistics Data Analysis*, v. 45, p. 215–233, 03 2004. Citado 4 vezes nas páginas 13, 20, 26 e 27.

CRIBARI-NETO, F.; ZEILEIS, A. Beta regression in r. *Journal of Statistical Software*, v. 34, p. 1–24, 04 2010. Citado 3 vezes nas páginas 13, 20 e 27.

DAEHLER, T. B.; AIZENMAN, J.; JINJARAK, Y. Emerging markets sovereign cds spreads during covid-19: Economics versus epidemiology news. *Economic Modelling*, Elsevier, v. 100, p. 105504, 2021. Citado na página 62.

DANISMAN, G.; DEMIR, E.; ZAREMBA, A. Financial resilience to the covid-19 pandemic: The role of banking market structure. *Applied Economics*, p. 1–24, 03 2021. Citado na página 62.

DATTA, R. et al. Statistical modeling of covid-19 pandemic stages worldwide. 05 2020. Citado 2 vezes nas páginas 13 e 21.

DEHEJIA, R.; MORDUCH, J.; MONTGOMERY, H. Do interest rates matter? credit demand in the dhaka slums. *SSRN Electronic Journal*, 10 2005. Citado na página 43.

FAVA, V. L. *Análise de Séries de Tempo*. São Paulo: Ed. Atlas, 2000. ISBN 85-224-2154-4. Citado na página 65.

FERMAN, B. Reading the fine print: Information disclosure in the brazilian credit card market. *Manag. Sci.*, v. 62, p. 3534–3548, 2016. Citado na página 44.

FERRARI, S.; CRIBARI-NETO, F. Beta regression for modelling rates and proportions. *Journal of Applied Statistics*, v. 31, p. 799 – 815, 2004. Citado na página 25.

FREUND, Y.; SCHAPIRE, R. E. et al. Experiments with a new boosting algorithm. In: CITESEER. *icml*. [S.l.], 1996. v. 96, p. 148–156. Citado na página 65.

HAMILTON, J. D. A new approach to the economic analysis of nonstationary time series and the business cycle. *Econometrica*, [Wiley, Econometric Society], v. 57, n. 2, p. 357–384, 1989. ISSN 00129682, 14680262. Disponível em: <<http://www.jstor.org/stable/1912559>>. Citado na página 50.

HANSEN, B. E. Testing for parameter instability in linear models. *Journal of Policy Modeling*, v. 14, n. 4, p. 517–533, 1992. ISSN 0161-8938. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0161893892900199>>. Citado 3 vezes nas páginas 18, 19 e 24.

HASAN, I.; POLITSIDIS, P.; SHARMA, Z. Bank lending during the covid-19 pandemic. *MPRA Paper 103565*, University Library of Munich, Germany, 2020. Citado na página 62.

HJORT, N.; KONING, A. Tests for constancy of model parameters over time. *Journal of Nonparametric Statistics - J NONPARAMETR STAT*, v. 14, p. 113–132, 04 2002. Citado 4 vezes nas páginas 18, 19, 23 e 24.

HOLT, C. C. Forecasting seasonals and trends by exponentially weighted moving averages. *International journal of forecasting*, Elsevier, v. 20, n. 1, p. 5–10, 2004. Citado na página 66.

HURSH, S. Hursh sr. economic concepts for the analysis of behavior. *J exp anal behav* 34: 219-238. *Journal of the experimental analysis of behavior*, v. 34, p. 219–38, 10 1980. Citado na página 50.

HURSH, S. R. Behavioral economics. *Journal of the Experimental Analysis of Behavior*, v. 42, n. 3, p. 435–452, 1984. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1901/jeab.1984.42-435>>. Citado na página 50.

HYNDMAN, R.; KHANDAKAR, Y. Automatic time series forecasting: The forecast package for r. *Journal of Statistical Software*, v. 26, 07 2008. Citado na página 67.

HYNDMAN, R. et al. A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of Forecasting*, v. 18, p. 439–454, 02 2002. Citado na página 67.

HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: principles and practice*. [S.l.]: OTexts, 2018. Citado 3 vezes nas páginas 65, 66 e 68.

- JAMES, G. et al. *An introduction to statistical learning*. [S.l.]: Springer, 2013. v. 112. Citado na página 67.
- JORDÀ, ; SINGH, S. R.; TAYLOR, A. M. *Longer-run Economic Consequences of Pandemics*. [S.l.], 2020. (Working Paper Series, 26934). Disponível em: <<http://www.nber.org/papers/w26934>>. Citado 2 vezes nas páginas 63 e 90.
- JUSHAN, B.; PERRON, P. Estimating and testing linear models with multiple structural changes. *Econometrica*, v. 66, n. 1, p. 47–48, 1998. Citado 2 vezes nas páginas 20 e 52.
- KARLAN, D.; ZINMAN, J. Credit elasticities in less-developed economies: Implications for microfinance. *American Economic Review*, v. 98, p. 1040–68, 02 2008. Citado 2 vezes nas páginas 44 e 56.
- KIM, C.-J.; MORLEY, J.; NELSON, C. The structural break in the equity premium. *Journal of Business Economic Statistics*, v. 23, p. 181–191, 02 2005. Citado na página 50.
- KUAN, C.-M.; HORNIK, K. The generalized fluctuation test: A unifying view. *Econometric Reviews*, Taylor Francis, v. 14, n. 2, p. 135–161, 1995. Disponível em: <<https://doi.org/10.1080/07474939508800311>>. Citado na página 19.
- LOUHICHI, W.; FTITI, Z.; AMEUR, H. B. Measuring the global economic impact of the coronavirus outbreak: Evidence from the main cluster countries. *Technological Forecasting and Social Change*, Elsevier, v. 167, p. 120732, 2021. Citado na página 63.
- LUNDBERG, E. L. Bancos oficiais e crédito direcionado – o que diferencia o mercado de crédito brasileiro? In: . [S.l.: s.n.], 2011. Citado na página 49.
- MENDONÇA, M.; MOREIRA, T.; SACHSIDA, A. Uma avaliação da demanda creditícia para automóveis no Brasil no período de 2000 a 2012. *Economia e Sociedade*, v. 26, p. 427–457, 08 2017. Citado na página 45.
- NARAYAN, P.; PHAN, D.; LIU, G. Covid-19 lockdowns, stimulus packages, travel bans, and stock returns. *Finance Research Letters*, v. 38, p. 101732, 08 2020. Citado 2 vezes nas páginas 62 e 90.
- NEGRI, J. A. D. et al. Elasticidades juros e prazo da demanda de crédito livre e direcionado no Brasil. In: ASSOCIAÇÃO NACIONAL DOS CENTROS DE PÓS-GRADUAÇÃO EM ECONOMIA - ANPEC. [S.l.], 2018. Citado 3 vezes nas páginas 41, 45 e 54.

NELSON, C. R.; PLOSSER, C. R. Trends and random walks in macroeconomic time series: Some evidence and implications. *Journal of Monetary Economics*, v. 10, n. 2, p. 139–162, 1982. ISSN 0304-3932. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0304393282900125>>. Citado na página 20.

NYBLOM, J. Testing for the constancy of parameters over time. *Journal of the American Statistical Association*, v. 84, n. 405, p. 223–230, 09 1989. Citado 3 vezes nas páginas 18, 19 e 24.

OLIVEIRA, G.; WOLF, P. A dinâmica do mercado de crédito no brasil no período recente (2007-2015). *2243 Texto para discussão. Instituto de Pesquisa Econômica Aplicada*, 2016. Citado na página 36.

PAOLINO, P. Maximum likelihood estimation of models with beta-distributed dependent variables. *Political Analysis*, v. 9, 01 2001. Citado na página 26.

PARAB, N.; REDDY, Y. The dynamics of macroeconomic variables in indian stock market: a bai-perron approach. *Macroeconomics and Finance in Emerging Market Economies*, v. 13, p. 1–25, 07 2019. Citado na página 50.

PINDYCK, R.; RUBINFELD, D. L. *Econometria: Modelos e Previsões*. Rio de Janeiro: Ed. Elsevier, 2004. ISBN 85-8680493-2. Citado na página 65.

PLOBERGER, W.; KRÄMER, W. Econometrica. *Econometrica*, v. 60, n. 2, p. 271–285, 1992. Citado na página 19.

PLOBERGER, W.; KRÄMER, W. A trend-resistant test for structural change based on ols residuals. *Journal of Econometrics*, v. 70, n. 1, p. 175–185, 1996. ISSN 0304-4076. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0304407694016887>>. Citado na página 19.

QUANDT, R. Tests of the hypothesis that a linear regression system obeys two separate regimes. *Journal of the American Statistical Association*, v. 55, p. 324–330, 1960. Citado na página 18.

R Core Team. *R: A Language and Environment for Statistical Computing*. Vienna, Austria, 2020. Disponível em: <<https://www.R-project.org/>>. Citado 2 vezes nas páginas 50 e 64.

REB. Relatório de economia bancária, 2017. *Banco Central do Brasil*, 2017. Citado 5 vezes nas páginas 12, 15, 36, 37 e 39.

REB. Relatório de economia bancária, 2020. *Banco Central do Brasil*, 2020. Citado 5 vezes nas páginas 14, 15, 39, 42 e 49.

SHAHBAZ, M.; HAOUAS, I.; SOHAG, K. The financial development-environmental degradation nexus in the united arab emirates: the importance of growth, globalization and structural breaks. *Environmental Science and Pollution Research*, v. 27, 04 2020. Citado na página 22.

SILVA, A. M. L. e. *Crédito Direcionado e Política Monetária: Uma Aplicação do Modelo de Vetores Auto-Regressivos*. Tese (Doutorado) — PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO, 2015. Citado na página 41.

STÜBINGER, J.; ADLER, K. How to identify varying lead-lag effects in time series data: Implementation, validation, and application of the generalized causality algorithm. *Algorithms*, v. 13, n. 4, 2020. ISSN 1999-4893. Disponível em: <<https://www.mdpi.com/1999-4893/13/4/95>>. Citado na página 21.

TAYLOR, S. J.; LETHAM, B. Forecasting at scale. *The American Statistician*, Taylor & Francis, v. 72, n. 1, p. 37–45, 2018. Citado 2 vezes nas páginas 68 e 69.

TELLI Şahin; CHEN, H. Structural breaks and trend awareness-based interaction in crypto markets. *Physica A: Statistical Mechanics and its Applications*, v. 558, p. 124913, 2020. ISSN 0378-4371. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378437120304726>>. Citado na página 21.

TZAVALIS, E.; MELIGKOTSIDOU, L.; VRONTOS, I. A bayesian analysis of unit roots and structural breaks in the level, trend, and error variance of autoregressive models of economic series. *Econometric Reviews*, v. 30, p. 208–249, 01 2011. Citado 2 vezes nas páginas 20 e 21.

WENG, R. J. B. . J. F. U. . J. The coronavirus and the great influenza pandemic: Lessons from the “spanish flu” for the coronavirus’s potential effects on mortality and economic activity. *National Bureau of Economic Research*,, 2020. Citado na página 63.

WINTERS, P. R. Forecasting sales by exponentially weighted moving averages. *Management science*, INFORMS, v. 6, n. 3, p. 324–342, 1960. Citado na página 66.

WOHAR, M.; RAPACH, D. Regime changes in international real interest rates: Are they a monetary phenomenon? *Journal of Money, Credit and Banking*, v. 37, p. 887–906, 02 2005. Citado na página 50.

XING, H. et al. Statistical surveillance of structural breaks in credit rating dynamics. *Entropy*, v. 22, n. 10, 2020. ISSN 1099-4300. Disponível em: <<https://www.mdpi.com/1099-4300/22/10/1072>>. Citado na página 21.

ZEILEIS, A. A unified approach to structural change tests based on ml scores, f statistics, and ols residuals. *Econometric Reviews*, Taylor Francis, v. 24, n. 4, p. 445–466, 2005. Disponível em: <<https://doi.org/10.1080/07474930500406053>>. Citado 2 vezes nas páginas 20 e 23.

ZEILEIS, A. Implementing a class of structural change tests: An econometric computing approach. *Computational Statistics Data Analysis*, v. 50, n. 11, p. 2987–3008, 2006. ISSN 0167-9473. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0167947305001477>>. Citado 5 vezes nas páginas 13, 20, 23, 25 e 39.

ZEILEIS, A.; HORNIK, K. Generalized m-fluctuation tests for parameter instability. *Stat. Neerland*, v. 61, 07 2003. Citado 2 vezes nas páginas 19 e 25.

ZEILEIS, A. et al. Testing and dating of structural changes in practice. *Computational Statistics Data Analysis*, v. 44, p. 109–123, 02 2003. Citado 2 vezes nas páginas 24 e 50.

ZEILEIS, A. et al. strucchange: An r package for testing for structural change in linear regression models. *Journal of Statistical Software, Articles*, v. 7, n. 2, p. 1–38, 2002. Disponível em: <<https://www.jstatsoft.org/v007/i02>>. Citado na página 20.