

**UNIVERSIDADE DE SÃO PAULO**  
**FACULDADE DE ECONOMIA, ADMINISTRAÇÃO, CONTABILIDADE E ATUÁRIA**  
**DEPARTAMENTO DE ECONOMIA**

**GUSTAVO STROISCH ANDRADE**

**TAXA DE JUROS E DEMANDA POR CRÉDITO PJ NO BRASIL: ESTUDO  
EMPÍRICO SOBRE A ELASTICIDADE-JUROS NO MERCADO DE CRÉDITO**

**SÃO PAULO**  
**2022**

**GUSTAVO STROISCH ANDRADE**

**TAXA DE JUROS E DEMANDA POR CRÉDITO PJ NO BRASIL: ESTUDO  
EMPÍRICO SOBRE A ELASTICIDADE-JUROS NO MERCADO DE CRÉDITO**

Monografia apresentada à Faculdade de Economia, Administração, Contabilidade e Atuária da Universidade de São Paulo, para obtenção do título de Bacharel em Ciências Econômicas.

Orientador: Cláudio Ribeiro de Lucinda  
Coordenador: Luís Eduardo Negrão Meloni

**SÃO PAULO**

**2022**

## **FICHA CATALOGRÁFICA**

Andrade, Gustavo Stroisch

Taxa de juros e demanda por crédito PJ no Brasil: estudo empírico sobre a elasticidade-juros no mercado de crédito – São Paulo, 2022.

Nº de páginas: 42

Orientador: Prof. Dr. Cláudio Ribeiro de Lucinda.

Tese de Graduação – Faculdade de Economia, Administração, Contabilidade e Atuária da Universidade de São Paulo (FEA-USP).

1. elasticidade de taxa de juros; 2. demanda por crédito; 3. seleção adversa  
Códigos JEL: D00; D01; D12; C01; G21; O16

## **AGRADECIMENTOS**

Agradeço primeiramente à minha família, a qual sempre demonstrou apoio e desempenhou papel central em minha formação como cidadão, dando os incentivos necessários aos projetos que desejei buscar.

Aos professores, funcionários e colegas da FEA-USP, com os quais pude aprender e participar de um ambiente plural e fecundo à diversidade.

Ao Prof. Dr. Cláudio Ribeiro de Lucinda, o qual aceitou me orientar no desenvolvimento deste trabalho.

Por fim, à empresa “Adiante Recebíveis”, a qual me abriu as portas ao mercado de trabalho e concordou em realizar a cessão dos dados necessários à elaboração deste trabalho.

## SUMÁRIO

<b>LISTA DE ILUSTRAÇÕES .....</b>	<b>IV</b>
<b>RESUMO.....</b>	<b>V</b>
<b>1 INTRODUÇÃO .....</b>	<b>7</b>
1.1 CONTEXTO DE MERCADO .....	7
1.2 OBJETIVOS .....	7
<b>2 REVISÃO DE LITERATURA .....</b>	<b>10</b>
2.1 AMBIENTE JURÍDICO-ECONÔMICO FAVORÁVEL .....	10
2.2 TAXA DE JUROS E PROBLEMAS INFORMACIONAIS .....	11
<b>3 METODOLOGIA .....</b>	<b>15</b>
3.1 CLUSTERIZAÇÃO DOS CLIENTES EM GRUPOS HOMOGÊNEOS .....	15
3.2 MODELOS DE REGRESSÃO E ANÁLISES EMPREGADAS .....	19
3.2.1 MODELO TOBIT .....	20
3.2.2 MODELO OLS LOG-LINEAR .....	21
3.2.3 MODELO OLS LOG-LOG (VOLUME OPERADO) .....	21
3.2.4 MODELO OLS LOG-LOG (PERCENTUAL DE LIMITE UTILIZADO) .....	22
<b>4 RESULTADOS.....</b>	<b>24</b>
<b>5 CONCLUSÕES .....</b>	<b>27</b>
<b>REFERÊNCIAS.....</b>	<b>28</b>
<b>APÊNDICES.....</b>	<b>29</b>

## LISTA DE ILUSTRAÇÕES

FIGURA 1 – FUNÇÃO GERADORA BHV SCORE .....	16
FIGURA 2 – DISTRIBUIÇÃO DOS CHOQUES EXÓGENOS DA TAXA DE DESÁGIO MENSAL.....	16
FIGURA 3 – DISTRIBUIÇÃO DO NÚMERO DE OBSERVAÇÕES POR PERÍODO E POR SCORE .....	17
FIGURA 4 – DISTRIBUIÇÃO DO VOLUME OPERADO POR GRUPO DE TESTE.	18
FIGURA 5 – DISTRIBUIÇÃO DO FATURAMENTO E LIMITE POR GRUPO DE TESTE .....	19

## RESUMO

Taxa de juros e demanda por crédito PJ no Brasil: estudo empírico sobre a elasticidade-juros no mercado de crédito.

**Resumo:** O presente trabalho tem como objetivo estimar a elasticidade juros-demanda por crédito da modalidade de antecipação de recebíveis para o mercado PJ brasileiro a partir dos dados de operação extraídos de uma fintech do setor. Para tal, empregou-se o uso de modelos de regressão TOBIT e OLS a fim de se observar também a separação dessa sensibilidade condicionada ao perfil comportamental de cada cliente dentro da plataforma.

**Palavras-chave:** Elasticidade de taxa de juros, demanda por crédito, seleção adversa.

**Códigos JEL:** D00, D01, D12, C01, G21, O16

## **1 INTRODUÇÃO**



# 1 INTRODUÇÃO

## 1.1 CONTEXTO DE MERCADO

A expansão do mercado de crédito brasileiro, em grande medida protagonizada pelo advento das fintechs e outras entidades de serviços financeiros, possibilitou a oferta de crédito mais ampla e menos custosa a grande parte das pequenas e médias empresas. Nesse sentido, tal oferta favoreceu a concessão de crédito a um novo rol de indivíduos, que antes não tinham acesso a soluções financeiramente viáveis, e fomentou uma nova dinâmica nesse mercado, a partir de taxas e prazos mais flexíveis. Esse novo cenário tende a diminuir as fricções desse processo e viabiliza um estudo mais assertivo quanto à sensibilidade desses tomadores de menor porte aos condicionantes da oferta de crédito.

Nesse sentido, a carência histórica do acesso ao crédito no Brasil não só deflagrava a ineficiência do mercado, bem como levava ao achatamento dos investimentos e conseqüente menor produtividade.

A relação do crédito privado sobre o produto interno bruto (PIB) brasileiro é inferior aos demais países no mundo. No período de 2003 a 2005, essa relação era de apenas 25%. Foi a partir de 2005 que o crédito começou a crescer mais significativamente. Entre 2013 e 2015, essa relação foi de 50% no Brasil. Esse percentual correspondia a 70% no Chile e na África do Sul e quase 120% na China. Apenas um pequeno número de empresas, geralmente de grande porte, consegue se livrar das restrições de crédito no mercado financeiro brasileiro (De Negri et al., 2018, p.149).

## 1.2 OBJETIVOS

Fundamentado nessas premissas, o objetivo geral deste trabalho é estimar precisamente a elasticidade-juro-demanda por crédito do produto “antecipação de NFe” para o grupo de clientes da fintech “Adiante Recebíveis”, a partir de choques exógenos de taxa para diferentes clusters homogêneos dentro do segundo semestre de 2022, e verificar qual seria a sensibilidade desses clientes ao aumento das taxas, dadas características específicas dos tomadores de crédito.

Adicionalmente, também pretende-se estudar como se dá a seleção adversa condicionada ao prazo e à taxa (termos do contrato) para a liquidez das operações, atentar para a margem intensiva (montante emprestado) e verificar se características intrínsecas às empresas são relevantes para se determinar essa dinâmica (faturamento, porte, rentabilidade, setor econômico etc.).

Espera-se encontrar uma elasticidade condicionada à qualidade de cada cluster de clientes (dada a métrica interna de behaviour score), sendo os melhores estratos mais sensíveis a choques positivos de taxa. Também se acredita que termos mais severos (prazos mais curtos a taxas mais altas) afetem de forma mais significativa o pool de bons clientes, sendo determinante para o seu montante tomado em crédito.

Dada a maior dinamicidade do mercado de crédito, faz-se necessário entender por completo o grau e os determinantes da sensibilidade dos agentes a choques de taxa de juros, em especial para produtos específicos como o de antecipação de recebíveis.

## **2 REVISÃO DE LITERATURA**

## 2 REVISÃO DE LITERATURA

### 2.1 AMBIENTE JURÍDICO-ECONÔMICO FAVORÁVEL

Como Ferreira (2019) buscou analisar, as instituições do mercado e agentes regulatórios do governo (como o Conselho Monetário Nacional e o próprio Bacen) atuaram na construção de um ambiente jurídico-econômico mais favorável a inovação e, com a inserção de novas empresas concessionárias de crédito, operando sem a vinculação a bancos ou até mesmo com forte participação de capital estrangeiro, o mercado atuou no sentido da expansão de produtos de crédito alternativos e pressão pela redução das taxas de juros.

Mesmo que o volume de crédito concedido pelo ecossistema das fintechs ainda represente uma parcela pequena, quando comparado ao montante total dos fluxos de capitais, a taxa de crescimento dentro de um curto espaço de tempo e a atenção dada, por órgãos regulatórios, a novas formas de interação econômica – vide o PIX, Open-banking e o Real digital, por exemplo – demonstram a tendência de longo prazo e o interesse público em fomentar esse ambiente mais flexível.

Episódios que comprovam esse alinhamento são os marcos regulatórios passados pelos governos britânico e estadunidense (2017 e 2018). Para o caso inglês, o “*Financial Conduct Authority Innovation Hub*” determinou que as fintechs pudessem operar num ambiente *sandbox*: dada uma licença provisória, as empresas poderiam operar isentas de sanções punitivas dentro destes ambientes de experimentação, testando novos produtos e soluções, a fim de se desenvolver – em conjunto com os reguladores estatais – regras que conversassem com essas novas formas de negócio. Pouco tempo depois, o “*Office of the Comptroller of the Currency*” estadunidense passou uma regulação específica para o funcionamento das fintechs, aproximando a legislação dos EUA ao *sandbox* britânico.

Para o cenário brasileiro, durante o mesmo período, Ferreira (2019) salienta a alta concentração da oferta de crédito: segundo dados do Bacen, para o ano de 2017, os cinco maiores bancos comerciais detinham cerca de 80% do crédito concedido e 71% dos ativos totais. Em contrapartida, o número de fintechs operando no mercado, segundo dados da Finnovation, saltou de 309 em outubro/2017 para 504 empresas em setembro/2019, o que representa um crescimento de mais de 63%.

Fator importante para esse crescimento, segundo Ferreira (2019), foi a regulamentação da atuação das fintechs pelo CMN, em abril de 2018, por meio das resoluções nº 4.656 e 4.657, criando-se duas novas variedades de instituições não-bancárias: a Sociedade de Crédito Direto (SCD) e a Sociedade de Empréstimo entre Pessoas (SEP). Esses dois corpos jurídicos possibilitaram a inserção de novas modalidades de crédito no mercado brasileiro, como o crédito “peer-to-peer” (onde credores e devedores são conectados por plataformas digitais) e a atuação das fintechs como “intermediadores financeiros” dentro de modalidades já consagradas, como empréstimos (com e sem garantia), consignados e desconto de duplicatas (mercado onde se insere a empresa a ser analisada neste trabalho).

Complementar a esse novo modelo, em dezembro/2020, por meio da resolução nº 4.685, o CMN cria o “Ambiente Controlado de Testes para Inovações Financeiras”: *sandbox* regulatório muito semelhante ao britânico e estadunidense.

## 2.2 TAXA DE JUROS E PROBLEMAS INFORMACIONAIS

Alinhado a essas transformações na estrutura jurídico-econômica, o contexto vivido pelos mercados emergentes, até então, diferia muito do observado em economias já desenvolvidas: tanto pela questão institucional mais avançada quanto pela abrangência do acesso ao crédito pulverizado dessas últimas.

Nesse cenário, como foi estudado por De Lucinda e Vieira (2014), foi proposto um experimento empírico que consistia na oferta de uma linha adicional de crédito a clientes de uma grade emissora de cartões de crédito, subdivididos em dois grupos homogêneos de renda média: um com renda mensal média de R\$3.500 (Grupo P) e outro de renda mensal média de R\$1.500 (Grupo I). A estes grupos, então, foi aleatorizada a oferta do crédito, cobrando-se bandas distintas de taxa a cada cliente. Para o grupo de renda mais elevada, tivemos um efeito claro da taxa de juros sobre a decisão de tomar o empréstimo (margem extensiva), porém isso não afetou tão fortemente o montante emprestado (margem intensiva). Ao passo que, para o grupo de menor renda, não houve sensibilidade relevante à taxa de juros em nenhum dos casos.

Para essas estimações da sensibilidade à taxa de juros, De Lucinda e Vieira (2014) fizeram uso de dois modelos de regressão: 1. o primeiro consistia num PROBIT

da probabilidade de o cliente aceitar a oferta (margem extensiva), condicionado à taxa anual oferecida, o limite máximo liberado a ser tomado e um conjunto de controles referentes à qualidade do cliente e 2. o segundo buscava investigar o montante tomado (margem intensiva) a partir de um TOBIT com o mesmo conjunto de variáveis, agregado do valor da parcela a ser cobrada.

Dentro da margem extensiva, os resultados obtidos corroboravam que, na média, um aumento de 1% na taxa cobrada refletiu uma queda de 2,8% na probabilidade de um cliente do Grupo P tomar o empréstimo. Já na margem intensiva, na média, um aumento de 1% na taxa cobrada refletiu uma queda de 0,3% no volume tomado pelo Grupo P. Lembrando que o grupo de menor renda (I) mostrou-se insensível à mudança de taxa para as duas margens.

Nesse sentido, a literatura também corrobora que a seleção de clientes menos sensíveis a variações na taxa cobrada deflagra piores índices de risco e aqueles mais tendenciosos a aceitar a oferta acabam por ter índices de inadimplência mais severos. A partir disso, modelos que compartilham informações entre os concessionários de crédito se mostram eficientes na modelagem de risco para a camada de renda mais elevada, enquanto medidas governamentais de diminuição de taxas performaram mal em difundir crédito às camadas mais baixas, favorecendo um aumento mais agressivo nas camadas mais altas.

Alinhado a isso, a partir do modelo desenvolvido por Ausubel (1999), carácter muito semelhante foi observado para os testes randomizados nos EUA: 1. clientes que acenam positivamente às ofertas têm um maior risco médio e 2. ofertas com condições mais severas selecionaram um pool de clientes com maior risco de *default*.

Resultado muito semelhante também foi observado por Vieira (2010): a partir da seleção de dois grupos de rendas distintas, ele observou o comportamento dos consumidores quando submetidos ao mesmo produto de cartão de crédito, sendo alterada apenas a taxa de juros, por um período de um ano. Disso, ele concluiu que as faixas de renda mais elevada apresentaram uma sensibilidade à taxa bem mais aguda, tendo uma correlação direta também ao seu nível de risco. Taxas mais baixas acabaram convertendo um perfil de consumidor com um risco médio mais baixo.

De Negri et al. (2018) completa esse raciocínio ao esboçar a sensibilidade dos juros e prazo sobre a demanda por crédito de uma gama de 378 mil empresas - no hiato 2004-2017. Os resultados do modelo de regressão de dois estágios (2SLS)

atestam uma elasticidade de cerca de -1,10 para os juros e +0,30 para o prazo de pagamento, sendo que houve uma distinção entre o peso dessas variáveis para créditos livre e direcionado, corroborando o esboçado por De Lucinda e Vieira (2014) no cenário de alta renda de pessoas físicas, agora para o ambiente empresarial.

### **3 METODOLOGIA**



### 3 METODOLOGIA

Tendo em vista os resultados encontrados na literatura, o presente trabalho busca estudar a sensibilidade à mudança da taxa de juros para um grupo de empresas tomadoras de crédito pela modalidade de antecipação de recebíveis. Para tal, far-se-á uso de base de dados concedida pela companhia “Adiante Recebíveis”, pertencente ao “Grupo GCB”, para a pool de clientes do seu serviço de “antecipação de NFe”.

Tal base de dados tem carácter privado e foi coletada pelo próprio autor, em comum acordo com a fintech, a partir da extração e manipulação de banco de dados em MySQL. Serão observados uma série de dados individualizados dos clientes da fintech para o produto de antecipação, como volume operado, taxa de deságio, prazo médio de crédito, taxa de liquidez, ticket médio, setor econômico (CNAE), faturamento, porte, idade, natureza jurídica, UF e behaviour score (métrica de scoring interna). Acerca da LGPD, os dados utilizados neste trabalho serão tratados a fim de salvaguardar a privacidade dos clientes da fintech.

Nessa tocante, o trabalho conscreverá uma abordagem direta: fora aplicado um choque positivo sobre a taxa de desconto - a partir do mês de agosto/2022 - para 4 estratos distintos de clientes, segregados a partir do seu comportamento histórico na plataforma. Tal choque consta de duas magnitudes para cada estrato a fim de capturar, além da elasticidade-juros-demanda, também um possível efeito de seleção adversa da inadimplência.

#### 3.1 CLUSTERIZAÇÃO DOS CLIENTES EM GRUPOS HOMOGÊNEOS

Os clientes foram categorizados pelo seu behaviour score em quatro grupos distintos (S, A, B e C), sendo que cada grupo possuirá diferentes bandas de taxa fixa padrão. A estes grupos serão aplicados, de forma aleatória, dois choques positivos de taxa de deságio mensal, um moderado e outro mais agressivo, bem como também mantido um grupo controle (o qual tem sua taxa atual conservada). O choque moderado descreve um incremento médio na ordem de +0,71p.p. sobre o controle, enquanto o agressivo eleva as taxas na ordem de +1,19p.p.

A função geradora do BHV score é tal que:

FIGURA 1 – Função Geradora BHV Score

$$F(\alpha, \beta, \sigma, \gamma, \theta) = \alpha^4 \cdot \frac{3}{2 + e^{\frac{\beta + \sigma - 3}{\beta_c}}} \cdot \frac{3}{3 + e^{1 - \frac{\gamma}{\gamma_c}}} \cdot \frac{4}{4 + e^{1 - \frac{\theta}{\theta_c}}}$$

Fonte: Adiante Recebíveis.

Com  $\alpha$  sendo a liquidez ponderada por valores das parcelas operadas,  $\beta$  o atraso médio do cliente e  $\sigma$  seu desvio padrão,  $\gamma$  é o valor total liquidado pelo cliente e  $\theta$  o número de meses com operações efetuadas.

Além das variáveis relacionadas ao comportamento dos clientes de forma individual, os parâmetros de escala,  $\beta_c$ ,  $\gamma_c$ ,  $\theta_c$ , são definidos conforme o comportamento geral dos clientes dentro de uma janela de um ano a partir da data em que o score for calculado (no caso deste experimento, os meses de agosto, setembro e outubro de 2022), onde  $\beta_c$  é dado pela média de atraso que inclua 90% dos clientes, enquanto  $\gamma_c$  e  $\theta_c$  incluem 75% dos clientes em relação ao valor total quitado e meses com operação.

Ao cabo, o modelo tem como resultado uma variável contínua, variando-se de 0 a 1000, a qual é posteriormente distribuída entre 5 grupos discretos (S, A, B, C e D), sendo o último proibido de operar (dado o seu comportamento histórico).

Já os choques exógenos são tais que:

FIGURA 2 – Distribuição dos Choques Exógenos da Taxa de Deságio Mensal

Grupo/BHV score	S	A	B	C
controle	1,45%	2,10%	3,20%	4,50%
moderado	1,90%	2,90%	4,50%	4,80%
agressivo	2,70%	3,60%	4,70%	5,00%

Fonte: Elaboração própria.

Nesse sentido, vale ressaltar que os choques (moderado e agressivo) foram elaborados com vistas a uma certa sobreposição das taxas entre os scores, a fim de se observar o entroncamento das bandas de taxas entre clientes de características comportamentais distintas.

O universo estudado totaliza um rol de 6.777 operações segregadas de uma gama total de 294 clientes elegíveis, entre os meses de agosto e outubro de 2022. Como elegível, entende-se o cliente que – para o mês analisado – não apresentava inadimplência (dado que isso é um critério de bloqueio), marcação de fraude ou comportamento histórico indesejável na plataforma (o supracitado “BHV score D”). Ademais, dado o carácter exploratório apenas sobre a base de clientes operantes e homogêneos segundo os critérios do BHV Score, também foram desconsiderados os clientes novos (com menos de 3 meses de operação), pois ainda não seria possível categorizá-los dentro de um score comportamental.

Satisfeitas essas condições iniciais, a fim de se estudar os efeitos sobre a margem intensiva de cada grupo de score, foram consolidados os dados de operação de cada cliente para cada um dos meses analisados. Desta forma, temos as seguintes separações disponíveis:

FIGURA 3 – Distribuição do Número de Observações por Período e por Score

Número de observações	Agosto/2022	Setembro/2022	Outubro/2022
<b>Consolidado de operações (scores: S, A, B e C)</b>	189	222	238

  

Número de observações	S	A	B	C
<b>Consolidado de todas as observações por score (grupos controle e de choque moderado e agressivo; meses: agosto, setembro e outubro)</b>	163	83	202	201

Fonte: Elaboração própria.

Como cada cliente tem o seu score atualizado mensalmente sem que haja uma data específica para isso, podendo transitar entre as faixas de um mês para o outro ou mesmo dentro do próprio período analisado, para os consolidados, levamos em consideração o score de cada cliente no momento em que as operações foram realizadas.

Outra característica importante que devemos salientar, diferentemente de outros produtos de crédito, para a modalidade de antecipação de recebíveis, muitos clientes acabam por internalizar a taxa de deságio no fluxo de vendas, o que tende a diminuir o efeito dos choques de taxa sobre a probabilidade de operar, porém, conservando-se o efeito esperado sobre o montante operado. Ademais, o limite de crédito concedido possui carácter rotativo, ou seja, caso o cliente liquide alguma parte

do montante operado dentro do período analisado, ele pode apresentar um VOP (volume operado mensal) maior que o limite de crédito rotativo oferecido.

Ademais, vale ressaltar que o produto de antecipação se difere das demais modalidades de crédito por não apresentar um plano de pagamentos com parcelas fixas pré-definidas: por definição, a amortização do crédito tomado se dá diretamente pelo fluxo de recebimento das parcelas antecipadas, pois a credora se torna dona dos direitos creditórios auferidos com as vendas do cedente do recebível. Dessa forma, temos uma coobrigação de pagamento entre o cedente (tomador do crédito) e o comprador da mercadoria (sacado): o que, na prática, condiciona o pagamento do empréstimo a ambas as partes.

FIGURA 4 – Distribuição do volume operado por grupo de teste

BHV score / grupo teste	julho (pré choque)	agosto	setembro	outubro
S	VOP	VOP	VOP	VOP
1	R\$ 2.653.568,52	R\$ 1.399.257,75	R\$ 1.377.299,42	R\$ 1.901.113,76
2		R\$ 1.894.548,14	R\$ 2.218.945,52	R\$ 2.273.332,97
3		R\$ 1.504.830,14	R\$ 1.477.736,00	R\$ 1.499.551,94
A				
1	R\$ 1.716.471,77	R\$ 709.545,74	R\$ 755.946,06	R\$ 660.015,85
2		R\$ 681.357,05	R\$ 380.892,74	R\$ 392.856,26
3		R\$ 1.079.852,85	R\$ 692.193,02	R\$ 574.389,36
B				
1	R\$ 1.464.389,99	R\$ 779.281,70	R\$ 1.322.088,94	R\$ 2.140.617,56
2		R\$ 357.757,70	R\$ 585.965,00	R\$ 502.031,61
3		R\$ 874.760,55	R\$ 1.029.806,01	R\$ 1.206.010,28
C				
1	R\$ 1.040.636,13	R\$ 473.294,44	R\$ 649.886,87	R\$ 672.434,69
2		R\$ 296.056,66	R\$ 344.808,01	R\$ 257.035,09
3		R\$ 782.640,66	R\$ 883.443,54	R\$ 831.694,12
<b>TOTAL</b>	R\$ 6.875.066,41	R\$ 10.833.183,38	R\$ 11.719.011,13	R\$ 12.911.083,49

Fonte: Elaboração própria.

Como podemos observar pela distribuição do volume operado entre os grupos analisados, para a maior parte das segmentações, tivemos uma acumulação relativamente homogênea entre os grupos de mesmo score. Também devemos observar o crescimento contínuo do volume operado para os clusters elegíveis à operação.

FIGURA 5 – Distribuição do faturamento e limite por grupo de teste

BHV score / grupo teste	Qtd. Observações	Faturamento anual médio	Limite médio concedido
<b>S</b>	<b>163</b>		
1	50	R\$ 2.297.600,00	R\$ 202.895,20
2	57	R\$ 1.394.298,25	R\$ 184.051,93
3	56	R\$ 2.046.607,14	R\$ 178.399,46
<b>A</b>	<b>83</b>		
1	26	R\$ 3.726.153,85	R\$ 181.925,00
2	27	R\$ 1.131.851,85	R\$ 121.182,59
3	30	R\$ 1.235.892,86	R\$ 151.258,67
<b>B</b>	<b>202</b>		
1	73	R\$ 4.959.383,56	R\$ 148.069,18
2	58	R\$ 1.785.344,83	R\$ 118.086,21
3	71	R\$ 1.872.816,90	R\$ 132.053,80
<b>C</b>	<b>201</b>		
1	78	R\$ 1.321.217,95	R\$ 73.777,95
2	55	R\$ 1.338.727,27	R\$ 77.881,27
3	68	R\$ 3.272.500,00	R\$ 88.628,53

Fonte: Elaboração própria.

A partir da análise do faturamento anual médio e da média dos limites concedidos a cada grupo de teste, podemos destacar uma distribuição uniforme dos limites oferecidos, tendo em vista que são variáveis determinadas pelo motor de crédito da fintech. Entretanto, para o faturamento anual, observamos uma distribuição, de certa forma, desigual: como tal variável é obtida consultando-se bases externas (como o Serasa e a SoaWeb), analisando-se a base percebemos que os faturamentos parecem seguir um comportamento segregado por bandas e, contrastando-se com o volume originado por cada usuário, chega-se à conclusão de que são apenas aproximados (não sendo confiáveis a nível estatístico).

Por fim, para as análises aqui desenvolvidas, foram omitidas informações relevantes quanto ao emprego de ações promocionais, campanhas de ativação e eventos de marketing – como concessão de cupons, cashback e afins – dada a impossibilidade de se catalogar todas essas ocorrências durante o período analisado.

### 3.2 MODELOS DE REGRESSÃO E ANÁLISES EMPREGADAS

A partir do conjunto de dados supracitados, a fim de se estimar os efeitos marginais da taxa de juros sobre a demanda por crédito, foram empregados dois modelos de regressão já consagrados na literatura avaliada: o primeiro é um modelo TOBIT que busca avaliar como variável dependente o volume operado por mês de

cada cliente, tendo como referência a massa de operações totais do período e sendo submetido a uma série de variáveis controle de dados intrínsecos às empresas. Para este modelo, a variável dependente é contínua, respeitando-se as censuras inferior e superior de cada regressão avaliada. Para o segundo modelo empregado, foi escolhido um OLS padrão, tendo a mesma variável dependente contínua (porém logaritmizada) e o mesmo conjunto de variáveis controle. Este segundo modelo visa estudar a aderência estatística do primeiro.

Em caráter complementar, a fim de se capturar mais precisamente a elasticidade da taxa de juros e demanda por crédito, também foram desenvolvidos dois modelos de regressão log-log: um primeiro tendo como variável dependente o volume operado e um segundo tendo como dependente o percentual de limite utilizado pelo cliente dentro do período de um mês. Para ambos os modelos, também foram empregadas variáveis controles, como: idade e porte da empresa.

Nesses últimos, também se optou por controlar a regressão pela UF de cada cliente e o mês da operação: buscando-se enxergar como possíveis características regionais e/ou sazonais influenciariam na regressão.

### 3.2.1 Modelo TOBIT

Seguindo uma abordagem semelhante à empregada por De Lucinda e Vieira (2014), o modelo TOBIT desenvolvido busca avaliar o apetite por crédito dos clientes segundo a seguinte forma funcional:

$$y = \alpha_0 + \gamma_i r + \beta_i X_i + \mu_1 x_3^2 + \epsilon$$

- Y é o volume antecipado dentro do período de um mês (como condicionante, devemos respeitar a censura inferior dado o menor volume operado no período e a censura superior dado o maior volume operado);
- $\alpha_0$  é o intercepto;
- r é a taxa de juros cobrada na operação;
- $X_i$  é um vetor de variáveis controle, tais que:
  - X1 é o prazo ponderado até o vencimento da parcela antecipada;
  - X2 é o total cobrado em spread para a operação;

- X3 é a idade da empresa no momento da operação;
- X4 é o tempo de cadastro do cliente (em dias);
- X5 é o porte da empresa (elencado de 1 a 5);
- X6 é a quantidade de boletos operados;
- X7 é o ticket médio desses boletos.
- $X3^2$  é a variável idade elevada ao quadrado;
- $\epsilon$  é o termo de erro relacionado.

### 3.2.2 Modelo OLS log-linear

Seguindo uma abordagem análoga ao TOBIT, o modelo OLS desenvolvido visa estimar o volume operado logaritmizado, condicionado às mesmas variáveis controle, seguindo a seguinte forma funcional:

$$\log(y) = \alpha_0 + \gamma_i r + \beta_i x_i + \mu_1 x_3^2 + \epsilon$$

Mesmo tendo acesso a outras variáveis correlatas às utilizadas por De Lucinda e Vieira (2014), como limite concedido e faturamento estimado, decidiu-se por não utilizar tais parâmetros nas regressões devido à questão da colinearidade e impressão estatística dessas (como foi discutido no tópico anterior). Então, optou-se pela utilização do porte (truncado entre 1 e 5) como substituto a essas variáveis, dado que é um componente mais abstrato que visa determinar as mesmas relações.

### 3.2.3 Modelo OLS log-log (volume operado)

Buscando avaliar como a variação percentual na taxa cobrada influencia percentualmente o volume operado, o seguinte modelo com efeitos fixos foi elaborado, segundo a forma funcional:

$$\log(y) = \alpha_0 + \gamma_i \log(r) + \beta_i X_i + \lambda_t + \nu_r + \mu_1 x_3^2 + \rho_p + \epsilon$$

- Y é o volume antecipado dentro de um mês;
- $\alpha_0$  é o intercepto;

- $r$  é a taxa de juros cobrada na operação;
- $X_i$  é um vetor de variáveis controle, tais que:
  - $X_1$  é o prazo ponderado até o vencimento da parcela antecipada;
  - $X_2$  é o total cobrado em spread para a operação;
  - $X_3$  é a idade da empresa no momento da operação;
  - $X_4$  é o tempo de cadastro do cliente (em dias);
  - $X_5$  é o ticket médio desses boletos.
- $\lambda_t$  é uma variável controle que representa o mês da operação;
- $\nu_r$  é uma variável controle que representa a UF do cliente;
- $X_3^2$  é a variável idade elevada ao quadrado;
- $\rho_p$  é uma variável controle que representa o porte do cliente;
- $\epsilon$  é o termo de erro relacionado.

#### 3.2.4 Modelo OLS log-log (percentual do limite utilizado)

Seguindo a mesma premissa do modelo acima, porém buscando interpretar como a variação percentual na taxa cobrada influencia o percentual do limite utilizado, o seguinte modelo com efeitos fixos foi elaborado, segundo a forma funcional:

$$\log(y) = \alpha_0 + \gamma_i \log(r) + \beta_i X_i + \lambda_t + \nu_r + \mu_1 x_3^2 + \rho_p + \epsilon$$

- Onde  $Y$  é o percentual do limite utilizado em um mês;
- As demais variáveis seguem as mesmas do modelo anterior.



## **4 RESULTADOS**

## 4 RESULTADOS

### 4.1 ANÁLISE DAS REGRESSÕES

Os resultados das regressões estão expostos entre os apêndices de 1 ao 10.

Como podemos avaliar pelo contraste entre os resultados obtidos pelos modelos TOBIT e OLS log-linear propostos a cada score distinto de clientes (S, A, B e C), ambas as abordagens se mostraram relevantes estatisticamente, apresentando também coeficientes gama negativos atrelados ao aumento da taxa de juros e ao prazo de vencimento das parcelas antecipadas, o que tende a corroborar a robustez da afirmação de que, de fato, existe uma sensibilidade dos clientes ao aumento de taxa e prazos de vencimento mais alongados (que tende a aumentar o spread auferido das operações) e que essa sensibilidade tem correlação ao perfil homogêneo dos clientes.

Para o TOBIT estimado, o incremento de 1% na taxa cobrada representaria uma queda no volume operado segundo a seguinte magnitude (em nível) para os scores: S -29 mil; A -10 mil; B -16 mil e C -3 mil. Tais resultados estão em linha com a nossa suposição inicial de que taxas maiores tendem a diminuir o volume tomado em crédito pelas empresas.

No mais, para o modelo estimado para os clientes de melhor score (S), também ficou latente uma relação negativa entre o aumento do porte das empresas e uma consequente menor tomada de crédito (o que pode ser explicado pelo acesso mais amplo a outras formas de crédito no mercado).

Concomitante a isso, ao se observar o modelo TOBIT atrelado às safras consolidadas de operação (meses de agosto, setembro e outubro), o comportamento observado se repete tanto para a sensibilidade à taxa de juros quanto ao prazo de vencimento das parcelas.

Para além, com o objetivo de se estimar as elasticidades atreladas a cada perfil de cliente por score, a regressão OLS log-log ( $y = \text{total\_operado}$ ) exhibe resultados de sensibilidade à taxa estatisticamente relevantes apenas aos scores S, A e C, coeficientes de -0,818; -1,151 e -0,636. Ademais, as dummies de período ( $\lambda_t$ ) e região ( $\nu_r$ ) mostraram-se não-significantes. Adicionando-se as variáveis controle (idade e porte), o resultado se manteve (S -0,818; A -1,250 e C -0,633), o que

corroborar a visão de que não tivemos influências significativas relacionadas ao período da operação e à região do cliente.

Por fim, a última regressão log-log ( $y$  = percentual de limite utilizado) exibiu resultados significantes da sensibilidade aos juros apenas para o extrato de clientes S (-0,562). Entretanto, quando submetida aos mesmos controles (idade e porte), a significância é ajustada para os scores S e A (-0,587 e -0,804). Para este modelo, as dummies de período e região também se mantiveram não-significantes para a maior parte dos casos.

## **5 CONCLUSÕES**

## 5 CONCLUSÕES

De modo geral, ao cabo, as estimações dos modelos de regressão corroboraram as premissas iniciais relacionadas à sensibilidade do aumento da taxa de juros e a diminuição da demanda por crédito, desta vez, atrelada ao produto de antecipação de recebíveis.

Tanto os modelos OLS quanto TOBIT tiveram uma boa aderência estatística e conseguiram mostrar boa separação entre os resultados de elasticidade e efeito marginal para cada um dos scores observados, o que demonstra, de fato, uma agregação homogênea entre os clientes por score.

Os resultados observados também vão de encontro com a premissa de que clientes com um melhor histórico comportamental são mais sensíveis à taxa e mais seletivos quanto à tomada de crédito.

Quanto ao efeito esperado do porte das empresas, como temos um grupo de certa forma bem concentrado em torno de pequenas e médias empresas, a separação por porte não foi de encontro ao que esperávamos.

Fato curioso é que, comparativamente ao observado por De Lucinda e Vieira (2014) para a elasticidade de indivíduos PF ao aumento dos juros, as elasticidades observadas para o mercado PJ foram, na maior parte dos casos, mais agressivas. O que pode traçar o paralelo de que empresas, na média, são mais sensíveis que indivíduos (talvez devido a uma maior oferta de crédito) a aumentos de taxa de juros.

No mais, podemos concluir que a sensibilidade negativa ao aumento da taxa de juros, como observada para outras modalidades de crédito, foi também reproduzida para o produto de antecipação de recebíveis, tanto para o seu efeito geral quanto à sua seleção por perfil de tomador de crédito.

## REFERÊNCIAS

AUSUBEL, Lawrence M. **Adverse Selection in the Credit Card Market**. 1999. Artigo Acadêmico. University of Maryland.

DEAN, K.; ZINMAN, J. **Elasticities of Demand for Consumer Credit**. Working Papers 926, Economic Growth Center, Yale University, 2005.

DE LUCINDA, Claudio Ribeiro e VIEIRA, Rodrigo Luiz. **Interest Rates and Informational Issues in the Credit Market: Experimental Evidence from Brazil**. World Development, volume 59, 2014, pages 47-58.

DE NEGRI, João Alberto et al. **Elasticidade-juros e prazo da demanda de créditos livre e direcionado no brasil**. ENCONTRO NACIONAL DE ECONOMIA, v. 46, 2018.

FERREIRA, Alexandre Rebêlo. **Desenvolvimento entre garantia e elasticidade: a regulação das Fintechs de crédito no Brasil**. 2019. Tese de Doutorado. Universidade de São Paulo.

VIEIRA, Rodrigo Luiz. **Elasticidade de juros e seleção adversa na concessão de empréstimos para pessoas físicas no Brasil: o caso do crédito atrelado ao cartão de crédito**. 2010. Tese de Doutorado. FGV-SP

## APÊNDICE 1 - TOBIT VS OLS – CLIENTES S

TOBIT vs OLS - Clientes S		
	<i>Dependent variable:</i>	
	total_operado <i>censored regression</i> (1)	log(total_operado) <i>OLS</i> (2)
taxa_cobrada	-29,620.740*** (6,763.642)	-0.329*** (0.084)
prazo_ponderado	-1,918.143*** (185.125)	-0.011*** (0.002)
total_spread	47.925*** (2.650)	0.001*** (0.00003)
idade	746.041** (358.660)	0.002 (0.004)
tempo_plataforma	-13.171 (15.362)	0.0002 (0.0002)
factor(porte)3	-21,314.290*** (7,644.175)	-0.056 (0.095)
factor(porte)5	-30,255.000** (11,799.940)	-0.383*** (0.146)
qtd_boletos	83.246 (50.623)	0.001 (0.001)
ticket_médio_boletos	1.349*** (0.395)	0.00001*** (0.00000)
logSigma	10.650*** (0.056)	
Constant	130,771.600*** (18,300.370)	10.933*** (0.227)
Observations	163	163
R <sup>2</sup>		0.705
Adjusted R <sup>2</sup>		0.688
Log Likelihood	-1,945.752	
Akaike Inf. Crit.	3,913.503	
Bayesian Inf. Crit.	3,947.535	
Residual Std. Error		0.524 (df = 153)
F Statistic		40.697*** (df = 9; 153)
Note:	* p<0.1; ** p<0.05; *** p<0.01	

## APÊNDICE 2 - TOBIT VS OLS – CLIENTES A

TOBIT vs OLS - Clientes A		
	<i>Dependent variable:</i>	
	total_operado <i>censored</i> <i>regression</i> (1)	log(total_operado) <i>OLS</i> (2)
taxa_cobrada	-10,805.580*** (3,696.189)	-0.312** (0.137)
prazo_ponderado	-1,253.143*** (182.686)	-0.012* (0.007)
total_spread	24.895*** (1.807)	0.0004*** (0.0001)
idade	-651.281 (464.220)	-0.016 (0.017)
tempo_plataforma	33.911*** (11.269)	0.0003 (0.0004)
factor(porte)3	-2,213.257 (5,528.937)	-0.242 (0.205)
factor(porte)5	26,968.310** (12,730.790)	0.217 (0.473)
qtd_boletos	175.121*** (66.162)	0.007*** (0.002)
ticket_médio_boletos	1.312* (0.700)	0.00003 (0.00003)
logSigma	9.997*** (0.079)	
Constant	67,623.110*** (14,913.200)	10.837*** (0.554)
Observations	83	83
R <sup>2</sup>		0.589
Adjusted R <sup>2</sup>		0.539
Log Likelihood	-927.176	
Akaike Inf. Crit.	1,876.352	
Bayesian Inf. Crit.	1,902.959	
Residual Std. Error		0.817 (df = 73)
F Statistic		11.644*** (df = 9; 73)
Note:	* p<0.1; ** p<0.05; *** p<0.01	



## APÊNDICE 3 - TOBIT VS OLS – CLIENTES B

TOBIT vs OLS - Clientes B		
	<i>Dependent variable:</i>	
	total_operado <i>censored</i> <i>regression</i>	log(total_operado) <i>OLS</i>
	(1)	(2)
taxa_cobrada	-16,317.500*** (2,827.318)	-0.030 (0.089)
prazo_ponderado	-1,362.316*** (157.215)	-0.015*** (0.005)
total_spread	23.696*** (1.045)	0.0003*** (0.00003)
idade	108.549 (222.421)	0.001 (0.007)
tempo_plataforma	6.619 (7.345)	0.0002 (0.0002)
factor(porte)3	5,194.041 (4,370.358)	0.120 (0.137)
factor(porte)5	11,394.020 (7,878.157)	0.112 (0.247)
qtd_boletos	52.431 (70.337)	0.010*** (0.002)
ticket_médio_boletos	0.467* (0.275)	0.00004*** (0.00001)
logSigma	10.144*** (0.051)	
Constant	105,321.900*** (13,280.280)	9.332*** (0.416)
Observations	199	199
R <sup>2</sup>		0.665
Adjusted R <sup>2</sup>		0.649
Log Likelihood	-2,280.445	
Akaike Inf. Crit.	4,582.891	
Bayesian Inf. Crit.	4,619.117	
Residual Std. Error		0.797 (df = 189)
F Statistic		41.629*** (df = 9; 189)
Note:	* p<0.1; ** p<0.05; *** p<0.01	

## APÊNDICE 4 - TOBIT VS OLS – CLIENTES C

TOBIT vs OLS - Clientes C		
	<i>Dependent variable:</i>	
	total_operado <i>censored</i> <i>regression</i> (1)	log(total_operado) <i>OLS</i> (2)
taxa_cobrada	-3,672.056*** (1,148.381)	-0.267*** (0.084)
prazo_ponderado	-484.816*** (64.206)	0.001 (0.005)
total_spread	15.499*** (0.897)	0.0005*** (0.0001)
idade	34.841 (129.371)	0.016* (0.010)
tempo_plataforma	0.767 (2.817)	-0.00000 (0.0002)
factor(porte)3	447.251 (2,035.430)	0.173 (0.150)
factor(porte)5	14,084.000*** (4,463.766)	0.378 (0.328)
qtd_boletos	238.748*** (41.729)	0.017*** (0.003)
ticket_médio_boletos	1.043*** (0.120)	0.00004*** (0.00001)
logSigma	9.392*** (0.050)	
Constant	32,046.350*** (5,626.784)	9.538*** (0.414)
Observations	201	201
R <sup>2</sup>		0.581
Adjusted R <sup>2</sup>		0.561
Log Likelihood	-2,154.943	
Akaike Inf. Crit.	4,331.886	
Bayesian Inf. Crit.	4,368.223	
Residual Std. Error		0.883 (df = 191)
F Statistic		29.380*** (df = 9; 191)
Note:	* p<0.1; ** p<0.05; *** p<0.01	

## APÊNDICE 5 - COMPARATIVO ESTIMAÇÃO TOBIT ENTRE SCORES

TOBIT S x A x B x C				
	<i>Dependent variable:</i>			
	total_operado			
	(1)	(2)	(3)	(4)
taxa_cobrada	-29,620.740*** (6,763.642)	-10,805.580*** (3,696.189)	-16,317.500*** (2,827.318)	-3,672.056*** (1,148.381)
prazo_ponderado	-1,918.143*** (185.125)	-1,253.143*** (182.686)	-1,362.316*** (157.215)	-484.816*** (64.206)
total_spread	47.925*** (2.650)	24.895*** (1.807)	23.696*** (1.045)	15.499*** (0.897)
idade	746.041** (358.660)	-651.281 (464.220)	108.549 (222.421)	34.841 (129.371)
tempo_plataforma	-13.171 (15.362)	33.911*** (11.269)	6.619 (7.345)	0.767 (2.817)
factor(porte)3	-21,314.290*** (7,644.175)	-2,213.257 (5,528.937)	5,194.041 (4,370.358)	447.251 (2,035.430)
factor(porte)5	-30,255.000** (11,799.940)	26,968.310** (12,730.790)	11,394.020 (7,878.157)	14,084.000*** (4,463.766)
qtd_boletos	83.246 (50.623)	175.121*** (66.162)	52.431 (70.337)	238.748*** (41.729)
ticket_médio_boletos	1.349*** (0.395)	1.312* (0.700)	0.467* (0.275)	1.043*** (0.120)
logSigma	10.650*** (0.056)	9.997*** (0.079)	10.144*** (0.051)	9.392*** (0.050)
Constant	130,771.600*** (18,300.370)	67,623.110*** (14,913.200)	105,321.900*** (13,280.280)	32,046.350*** (5,626.784)
Observations	163	83	199	201
Log Likelihood	-1,945.752	-927.176	-2,280.445	-2,154.943
Akaike Inf. Crit.	3,913.503	1,876.352	4,582.891	4,331.886
Bayesian Inf. Crit.	3,947.535	1,902.959	4,619.117	4,368.223
<i>Note:</i>			* p<0.1; ** p<0.05; *** p<0.01	

# **APÊNDICE 6 - TOBIT POR SAFRA DE OPERAÇÃO (AGOSTO, SETEMBRO E OUTUBRO)**

<b>TOBIT POR SAFRA DE OPERAÇÃO</b>			
	<i>Dependent variable:</i>		
	total_operado		
	(1)	(2)	(3)
taxa_cobrada	-15,569.340*** (2,043.287)	-15,797.430*** (1,866.238)	-16,872.580*** (2,157.363)
prazo_ponderado	-1,144.745*** (161.871)	-1,068.997*** (137.799)	-1,453.809*** (150.863)
total_spread	25.445*** (1.519)	20.084*** (1.275)	32.894*** (1.592)
idade	150.673 (268.052)	354.512 (247.655)	213.847 (279.207)
tempo_plataforma	12.606 (8.098)	9.252 (7.159)	8.489 (7.572)
factor(porte)3	-1,460.936 (5,139.105)	-5,506.742 (4,614.852)	-8,392.736 (5,347.746)
factor(porte)5	7,829.852 (8,595.423)	-1,568.040 (8,588.548)	-902.845 (10,126.220)
qtd_boletos	103.864** (47.298)	291.181*** (44.302)	118.316* (69.293)
ticket_médio_boletos	0.856*** (0.235)	1.971*** (0.344)	0.905*** (0.343)
logSigma	10.331*** (0.052)	10.292*** (0.048)	10.473*** (0.046)
Constant	91,367.960*** (11,301.400)	91,485.410*** (11,240.970)	101,264.400*** (11,697.090)
Observations	189	221	237
Log Likelihood	-2,200.935	-2,568.198	-2,797.784
Akaike Inf. Crit.	4,423.871	5,158.397	5,617.568
Bayesian Inf. Crit.	4,459.530	5,195.776	5,655.717
Note:	* p<0.1; ** p<0.05; *** p<0.01		

## APÊNDICE 7 - REGRESSÃO OLS LOG-LOG TOTAL OPERADO ENTRE SCORES

	<i>Dependent variable:</i>			
	log(total_operado)			
	(1)	(2)	(3)	(4)
log(taxa_cobrada)	-0.818*** (0.199)	-1.151*** (0.413)	0.056 (0.361)	-0.636* (0.355)
factor(UF)AM			0.541 (0.984)	-0.816 (1.003)
factor(UF)BA			-0.007 (0.582)	-1.391 (0.953)
factor(UF)CE	0.259 (0.298)	0.447 (0.957)	0.779 (0.770)	-0.450 (1.290)
factor(UF)DF	-0.276 (0.289)		1.233 (0.985)	-0.995 (0.973)
factor(UF)ES	0.113 (0.370)	-0.247 (0.489)	-0.314 (0.786)	-2.851*** (1.031)
factor(UF)GO	-0.037 (0.282)	-0.175 (0.740)	0.110 (0.696)	-2.033** (0.974)
factor(UF)MA			0.536 (0.972)	-1.265 (1.293)
factor(UF)MG	-0.035 (0.220)	0.482 (0.994)	-0.147 (0.536)	-1.549* (0.934)
factor(UF)MS			-0.412 (0.723)	-0.451 (1.289)
factor(UF)MT	-0.180 (0.311)	-0.535 (0.943)	0.132 (0.697)	-2.635** (1.069)
factor(UF)PB		-1.329 (0.876)	-2.195** (1.024)	
factor(UF)PA				-2.321** (1.124)
factor(UF)PE	0.474 (0.580)	-0.419 (0.567)	-0.944 (0.771)	-1.397 (1.060)
factor(UF)PI		-0.080 (0.717)	-1.578 (0.965)	-1.944* (1.023)
factor(UF)PR	-0.064 (0.221)	-0.215 (0.544)	-0.225 (0.518)	-2.262** (0.938)
factor(UF)RJ	0.040 (0.184)	0.178 (0.456)	-0.162 (0.515)	-1.476 (0.945)
factor(UF)RS	0.237 (0.271)	0.006 (0.714)	1.111 (0.976)	-1.764* (0.984)
factor(UF)SC	0.368 (0.279)	-0.702 (0.452)	0.285 (0.569)	-1.757* (0.964)

factor(UF)SP	-0.048 (0.173)	-0.321 (0.454)	-0.034 (0.495)	-1.598* (0.921)
factor(mês_operação)8/2022	0.013 (0.112)	-0.103 (0.265)	-0.024 (0.150)	-0.022 (0.184)
factor(mês_operação)9/2022	0.077 (0.104)	0.416 (0.255)	-0.036 (0.146)	-0.280 (0.172)
prazo_ponderado	-0.011*** (0.003)	-0.016** (0.008)	-0.009 (0.006)	0.003 (0.005)
total_spread	0.001*** (0.00003)	0.001*** (0.0001)	0.0004*** (0.00003)	0.001*** (0.0001)
tempo_plataforma	0.0002 (0.0002)	0.0001 (0.0005)	-0.0001 (0.0002)	-0.0005** (0.0002)
ticket_médio_boletos	0.00001** (0.00001)	0.00002 (0.00002)	0.00003*** (0.00001)	0.00003*** (0.00001)
Constant	10.742*** (0.277)	11.454*** (0.635)	9.358*** (0.716)	11.496*** (1.049)
Observations	163	83	202	201
R <sup>2</sup>	0.697	0.631	0.666	0.598
Adjusted R <sup>2</sup>	0.657	0.511	0.619	0.540
Residual Std. Error	0.549 (df = 143)	0.841 (df = 62)	0.832 (df = 176)	0.903 (df = 175)
F Statistic	17.353*** (df = 19; 143)	5.290*** (df = 20; 62)	14.046*** (df = 25; 176)	10.410*** (df = 25; 175)
Note: *p<0.1; **p<0.05; ***p<0.01				

## APÊNDICE 8 - REGRESSÃO OLS LOG-LOG TOTAL OPERADO ENTRE SCORES (COM VARIÁVEIS CONTROLE)

	<i>Dependent variable:</i>			
	log(total_operado)			
	(1)	(2)	(3)	(4)
log(taxa_cobrada)	-0.818*** (0.197)	-1.250** (0.492)	-0.089 (0.378)	-0.633* (0.357)
factor(UF)AM			0.352 (0.987)	-0.805 (1.011)
factor(UF)BA			-0.092 (0.586)	-1.349 (0.975)
factor(UF)CE	0.125 (0.301)	0.222 (0.975)	0.856 (0.769)	-0.354 (1.311)
factor(UF)DF	-0.310 (0.306)		0.467 (1.091)	-1.129 (0.987)
factor(UF)ES	-0.044 (0.373)	-0.195 (0.513)	-0.337 (0.789)	-2.858*** (1.041)
factor(UF)GO	-0.140 (0.283)	-0.040 (0.758)	-0.182 (0.751)	-1.977* (1.005)
factor(UF)MA			0.643 (0.977)	-1.228 (1.310)
factor(UF)MG	0.053 (0.230)	0.220 (1.018)	-0.222 (0.539)	-1.564 (0.949)
factor(UF)MS			-0.409 (0.725)	-0.377 (1.309)
factor(UF)MT	-0.471 (0.332)	-0.733 (0.958)	0.066 (0.697)	-2.652** (1.081)
factor(UF)PB		-1.158 (0.986)	-2.038* (1.041)	
factor(UF)PA				-2.281** (1.143)
factor(UF)PE	0.416 (0.571)	-0.624 (0.584)	-0.901 (0.773)	-1.331 (1.084)
factor(UF)PI		-0.177 (0.761)	-1.622* (0.965)	-1.916* (1.036)
factor(UF)PR	-0.253 (0.229)	-0.297 (0.630)	-0.307 (0.521)	-2.235** (0.958)
factor(UF)RJ	-0.132 (0.189)	0.100 (0.484)	-0.286 (0.520)	-1.482 (0.966)
factor(UF)RS	0.016 (0.283)	-0.030 (0.719)	1.055 (0.982)	-1.812* (0.997)
factor(UF)SC	0.266 (0.282)	-0.794 (0.486)	0.219 (0.569)	-1.735* (0.974)

factor(UF)SP	-0.166 (0.177)	-0.355 (0.503)	-0.060 (0.497)	-1.588* (0.937)
factor(mês_operação)8/2022	-0.008 (0.109)	-0.164 (0.270)	-0.030 (0.152)	-0.032 (0.186)
factor(mês_operação)9/2022	0.057 (0.102)	0.411 (0.257)	-0.047 (0.147)	-0.283 (0.173)
prazo_ponderado	-0.013*** (0.003)	-0.016* (0.008)	-0.007 (0.006)	0.004 (0.005)
total_spread	0.001*** (0.00003)	0.001*** (0.0001)	0.0004*** (0.00003)	0.001*** (0.0001)
tempo_plataforma	0.0002 (0.0002)	0.0003 (0.001)	0.0001 (0.0003)	-0.0005** (0.0002)
ticket_médio_boletos	0.00002*** (0.00001)	-0.00001 (0.00003)	0.00003*** (0.00001)	0.00003*** (0.00001)
idade	0.021 (0.018)	-0.015 (0.040)	-0.035 (0.026)	0.0003 (0.030)
idade2	-0.0004 (0.0005)	0.001 (0.001)	0.001* (0.001)	0.0005 (0.001)
factor(porte)3	-0.057 (0.109)	-0.345 (0.236)	0.133 (0.158)	0.069 (0.176)
factor(porte)5	-0.516*** (0.174)	0.229 (0.545)	0.320 (0.291)	0.140 (0.349)
Constant	10.891*** (0.296)	11.787*** (0.731)	9.531*** (0.755)	11.406*** (1.083)
Observations	163	83	199	201
R <sup>2</sup>	0.718	0.652	0.675	0.603
Adjusted R <sup>2</sup>	0.672	0.508	0.619	0.536
Residual Std. Error	0.537 (df = 139)	0.843 (df = 58)	0.830 (df = 169)	0.908 (df = 171)
F Statistic	15.425*** (df = 23; 139)	4.532*** (df = 24; 58)	12.115*** (df = 29; 169)	8.951*** (df = 29; 171)
Note: *p<0.1; **p<0.05; ***p<0.01				



# APÊNDICE 9 - REGRESSÃO OLS LOG-LOG PERCENTUAL DE LIMITE UTILIZADO

	<i>Dependent variable:</i>			
	log(perc_limite_utilizado)			
	(1)	(2)	(3)	(4)
log(taxa_cobrada)	-0.562*** (0.208)	-0.476 (0.372)	0.286 (0.369)	-0.506 (0.399)
factor(UF)AM			0.767 (1.006)	-0.215 (1.129)
factor(UF)BA			0.165 (0.595)	-1.006 (1.071)
factor(UF)CE	0.125 (0.311)	-0.015 (0.861)	1.298 (0.787)	-0.325 (1.451)
factor(UF)DF	-0.077 (0.302)		2.245** (1.007)	-0.122 (1.095)
factor(UF)ES	0.130 (0.387)	-0.576 (0.440)	-0.294 (0.803)	-2.663** (1.160)
factor(UF)GO	-0.123 (0.295)	-0.442 (0.667)	-0.295 (0.712)	-1.832* (1.096)
factor(UF)MA			0.955 (0.994)	-0.992 (1.454)
factor(UF)MG	-0.137 (0.230)	0.177 (0.895)	-0.209 (0.548)	-1.239 (1.051)
factor(UF)MS			-0.712 (0.739)	-0.165 (1.450)
factor(UF)MT	0.021 (0.325)	-0.404 (0.849)	-0.105 (0.712)	-1.772 (1.203)
factor(UF)PB		-1.640** (0.789)	-1.740* (1.048)	
factor(UF)PA				-2.462* (1.264)
factor(UF)PE	0.723 (0.607)	-0.150 (0.511)	-1.139 (0.788)	-0.524 (1.193)
factor(UF)PI		-0.303 (0.646)	-0.984 (0.987)	-1.619 (1.151)
factor(UF)PR	-0.173 (0.231)	-0.041 (0.490)	-0.228 (0.530)	-2.076* (1.055)
factor(UF)RJ	0.090 (0.192)	0.150 (0.410)	-0.152 (0.526)	-1.066 (1.062)
factor(UF)RS	0.427 (0.283)	0.055 (0.643)	1.749* (0.998)	-1.506 (1.107)
factor(UF)SC	0.175 (0.292)	-0.688* (0.407)	0.166 (0.582)	-1.431 (1.084)

factor(UF)SP	-0.122 (0.181)	-0.401 (0.408)	-0.115 (0.506)	-1.179 (1.036)
factor(mês_operação)8/2022	-0.008 (0.117)	-0.244 (0.238)	-0.148 (0.154)	-0.506** (0.207)
factor(mês_operação)9/2022	0.060 (0.109)	0.211 (0.230)	-0.112 (0.149)	-0.543*** (0.194)
prazo_ponderado	-0.009*** (0.003)	-0.010 (0.007)	-0.003 (0.006)	0.007 (0.006)
total_spread	0.0005*** (0.00003)	0.0004*** (0.0001)	0.0003*** (0.00003)	0.0005*** (0.0001)
tempo_plataforma	0.0001 (0.0002)	-0.0002 (0.0004)	-0.00001 (0.0002)	-0.001*** (0.0003)
ticket_médio_boletos	0.00001 (0.00001)	0.00001 (0.00001)	0.00003*** (0.00001)	0.00003*** (0.00001)
Constant	-1.325*** (0.290)	-0.699 (0.572)	-2.588*** (0.733)	0.161 (1.180)
Observations	163	83	202	201
R <sup>2</sup>	0.620	0.562	0.545	0.489
Adjusted R <sup>2</sup>	0.569	0.421	0.481	0.416
Residual Std. Error	0.574 (df = 143)	0.757 (df = 62)	0.851 (df = 176)	1.015 (df = 175)
F Statistic	12.276*** (df = 19; 143)	3.979*** (df = 20; 62)	8.449*** (df = 25; 176)	6.694*** (df = 25; 175)
Note: *p<0.1; **p<0.05; ***p<0.01				

# APÊNDICE 10 - REGRESSÃO OLS LOG-LOG PERCENTUAL DE LIMITE UTILIZADO (COM VARIÁVEIS CONTROLE)

	<i>Dependent variable:</i>			
	log(perc_limite_utilizado)			
	(1)	(2)	(3)	(4)
log(taxa_cobrada)	-0.587*** (0.200)	-0.804* (0.439)	0.146 (0.387)	-0.500 (0.403)
factor(UF)AM			0.853 (1.011)	-0.265 (1.141)
factor(UF)BA			0.025 (0.600)	-1.035 (1.101)
factor(UF)CE	-0.078 (0.306)	-0.258 (0.871)	1.291 (0.788)	-0.340 (1.479)
factor(UF)DF	0.008 (0.311)		1.474 (1.117)	-0.138 (1.113)
factor(UF)ES	-0.104 (0.378)	-0.468 (0.458)	-0.374 (0.808)	-2.659** (1.175)
factor(UF)GO	-0.272 (0.288)	-0.217 (0.677)	-0.255 (0.769)	-1.870 (1.134)
factor(UF)MA			0.872 (1.001)	-0.947 (1.479)
factor(UF)MG	0.074 (0.234)	-0.064 (0.909)	-0.298 (0.552)	-1.230 (1.071)
factor(UF)MS			-0.705 (0.743)	-0.180 (1.477)
factor(UF)MT	-0.306 (0.338)	-0.609 (0.855)	-0.139 (0.714)	-1.719 (1.220)
factor(UF)PB		-1.330 (0.880)	-1.825* (1.066)	
factor(UF)PA				-2.428* (1.289)
factor(UF)PE	0.625 (0.580)	-0.340 (0.522)	-1.234 (0.792)	-0.590 (1.224)
factor(UF)PI		-0.505 (0.679)	-0.856 (0.989)	-1.596 (1.170)
factor(UF)PR	-0.394* (0.232)	0.033 (0.563)	-0.268 (0.533)	-2.103* (1.081)
factor(UF)RJ	-0.103 (0.192)	0.158 (0.432)	-0.214 (0.533)	-1.049 (1.090)
factor(UF)RS	0.163 (0.287)	0.019 (0.641)	1.522 (1.006)	-1.493 (1.125)
factor(UF)SC	0.032 (0.286)	-0.688 (0.434)	0.209 (0.583)	-1.461 (1.099)
factor(UF)SP	-0.231	-0.336	-0.149	-1.198

	(0.179)	(0.449)	(0.509)	(1.057)
factor(mês_operação)8/2022	-0.035 (0.111)	-0.276 (0.241)	-0.176 (0.155)	-0.500** (0.210)
factor(mês_operação)9/2022	0.031 (0.104)	0.220 (0.230)	-0.134 (0.150)	-0.547*** (0.195)
prazo_ponderado	-0.012*** (0.003)	-0.011 (0.008)	-0.004 (0.006)	0.006 (0.006)
total_spread	0.0005*** (0.00003)	0.0004*** (0.0001)	0.0003*** (0.00003)	0.0005*** (0.0001)
tempo_plataforma	0.00005 (0.0002)	-0.00001 (0.0005)	0.0001 (0.0003)	-0.001** (0.0003)
ticket_médio_boletos	0.00001** (0.00001)	-0.00001 (0.00003)	0.00003*** (0.00001)	0.00003*** (0.00001)
idade	0.021 (0.019)	-0.031 (0.035)	-0.034 (0.026)	-0.030 (0.034)
idade2	-0.001 (0.001)	0.001 (0.001)	0.001 (0.001)	0.001 (0.001)
factor(porte)3	-0.107 (0.110)	-0.364* (0.211)	-0.175 (0.162)	0.019 (0.198)
factor(porte)5	-0.749*** (0.176)	-0.267 (0.486)	-0.246 (0.298)	-0.155 (0.394)
Constant	-1.096*** (0.300)	-0.122 (0.653)	-2.129*** (0.774)	0.300 (1.222)
Observations	163	83	199	201
R <sup>2</sup>	0.666	0.595	0.555	0.492
Adjusted R <sup>2</sup>	0.611	0.427	0.478	0.406
Residual Std. Error	0.545 (df = 139)	0.753 (df = 58)	0.850 (df = 169)	1.024 (df = 171)
F Statistic	12.068*** (df = 23; 139)	3.548*** (df = 24; 58)	7.262*** (df = 29; 169)	5.710*** (df = 29; 171)
Note: *p<0.1; **p<0.05; ***p<0.01				