

UNIVERSIDADE FEDERAL DE PELOTAS
Instituto de Ciências Humanas
Programa de Pós-Graduação em Organizações e Mercados



Dissertação de Mestrado

FINTEHCS E O SISTEMA BANCÁRIO TRADICIONAL BRASILEIRO

Marcus Vinicius Bastos dos Santos

Pelotas, 2020

Marcus Vinicius Bastos dos Santos

FINTECHS E O SISTEMA BANCÁRIO TRADICIONAL BRASILEIRO

Dissertação apresentada ao Programa de Pós-Graduação em Organizações e Mercados do Instituto de Ciências Humanas da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Mestre em Economia Aplicada.

Orientador: Prof. Dr. Regis Augusto Ely

Pelotas, 2020

Marcus Vinicius Bastos dos Santos

FINTECHS E O SISTEMA BANCÁRIO TRADICIONAL BRASILEIRO

Dissertação aprovada, como requisito parcial para obtenção do grau de Mestre em Economia Aplicada, pelo Programa de Pós-Graduação em Organizações e Mercado do Instituto de Ciências Humanas da Universidade Federal de Pelotas.

Aprovado pela Banca Examinadora em ___/___/____.

Banca examinadora:

Professor Dr. Regis Augusto Ely (PPGOM/UFPEL)

Professor Dr. André Carraro (PPGOM/UFPEL)

Professor Dr. Guilherme Stein (UNISINOS)

Resumo

O objetivo desse trabalho é analisar como o surgimento das *fintechs* no mercado financeiro brasileiro afetou os indicativos bancários de renda, despesa e o desempenho das instituições financeiras (IFs) tradicionais. Para tanto, foi adotado uma abordagem econométrica com dados em painel, mais especificamente o modelo de Efeito Fixo, utilizando as informações sobre as instituições presentes no banco de dados do Banco Central do Brasil (BACEN) – o if.data – durante o período de março de 2010 até setembro de 2019. Os principais resultados encontrados mostraram que a amostra completa dos bancos tradicionais exibiram uma diminuição de 0.86% na renda oriunda de operações de crédito, também uma redução das tarifas e serviços bancários acima de 2%, e redução de despesas administrativas e com pessoal maior que 3.7%, além de uma postura migratória congruente com o avanço tecnológico do setor.

Palavras-chave: *fintechs*, mercado financeiro, sistema bancário, dados em painel.

Classificação JEL: G21, G23, M13, O33

Abstract

The objective of this paper is to analyze how the emergence of fintechs in the Brazilian financial market affected the banking index of income, expenses, and performance of the traditional financial institutions (FI). To accomplish this goal, was adopted an econometric approach with panel data, more specifically a Fixed Effects model, using the information over the financial institutions present in the Brazilian Central Bank (BCB) data base – the if.data – from the period of March 2010 to September 2019. The main results showed that the full sample of traditional banks exhibited a reduction of 0.86% in the income from credit operations, also a decreasing in the banking taxes and services fees above 2%, and a reduction in administrative and personnel costs greater than 3.7%, besides a changeful behavior congruent with the technological advancements in the sector.

Keywords: *fintechs*, financial market, banking system, panel data.

JEL Classification: G21, G23, M13, O33

LISTA DE FIGURAS

Figura 1. Evolução dos serviços digitais no Brasil.....	19
Figura 2. Número de instituições financeiras por intervalo de número médio de agências....	26

LISTA DE TABELAS

Tabela 1. Estatísticas descritivas	21
Tabela 2. Resultados da variável Renda de operações de crédito	27
Tabela 3. Resultados das variáveis de Renda e Despesas	29
Tabela 4. Resultados das variáveis de Desempenho	31
Tabela 5. Instituições Individuais – demonstrativo de resultado (DRE)	41
Tabela 6. Instituições Individuais – resumo	42
Tabela 7. Balanço: Ativo	42
Tabela 8. Resultado teste de endogeneidade de Hausman (1978)	44
Tabela 9. Resultados da variável Renda de operações de crédito pelo modelo de Efeitos Aleatórios	45
Tabela 10. Resultados das variáveis de Renda e Despesas pelo modelo de Efeitos Aleatórios	46
Tabela 11. Resultados das variáveis de Desempenho pelo modelo de Efeitos Aleatórios	47

SUMÁRIO

1. Introdução	7
2. Revisão da literatura	10
2.1 Contexto histórico	10
2.2 Regulamentação	12
2.3 <i>Fintechs</i> e o sistema bancário.....	14
3. Descrição dos dados	16
3.1 Filtragem	17
3.2 Caracterização das variáveis	18
4. Estratégia empírica	22
4.1 Pressupostos do modelo de Efeito Fixo	22
5. Resultados	25
5.1 Limitações	32
5.2 Análise de robustez.....	33
6. Conclusão	35
Referências	38
Apêndice	41

1. Introdução

A revolução trazida pela internet impulsionou o nascimento de inúmeras empresas intensivas em tecnologia. Novos modelos de negócios e conceitos tecnológicos provêm uma base para soluções inovadoras em finanças. Os consumidores no mercado financeiro estão demandando serviços inteligentes, intuitivos, independentes da localidade ou do horário, e a custos cada vez menores (GOMBER et al., 2017). Nesse sentido surgiram as *fintechs*, empresas que intensificam o uso da tecnologia para prover serviços financeiros, que até então eram providos tradicionalmente pelos bancos (LI et al., 2017).

A distinta taxonomia do termo *FinTech*, oriundo de *Financial Technology*, descreve os setores de tecnologia financeira em uma ampla gama de operações para empresas e organizações, que intensificam a qualidade de seus serviços através da aplicação da Tecnologia da Informação (TI) em seu escopo de negócios. Ainda, o termo tomou notoriedade pelo alto número de forças propulsoras, como desenvolvimento técnico, expectativas de inovação no mercado, necessidade de diminuir gastos, e as demandas dos consumidores (GAI et al., 2018).

A entrada desse novo modelo de negócio no mercado financeiro pode, segundo a teoria econômica, ser percebida como complementar aos serviços bancários tradicionais já existentes ou substituta. Os produtos são considerados complementares se ambos são consumidos conjuntamente satisfazendo as necessidades dos consumidores; e em contrapartida, são considerados substitutos se possuem uma aplicação em comum e um produto substitui o uso do outro, contemplando as mesmas necessidades dos consumidores (AAKER e KELLER, 1990).

No cenário brasileiro, conforme CHC Advocacia (2019), o endividamento bancário é um problema bastante comum, onde 52% dos brasileiros estão inscritos no Serviço de Proteção ao Crédito (SPC Brasil) por estarem endividados com seus bancos. Segundo dados do Banco Mundial, apenas US\$ 0.13 são recuperados de cada US\$ 1 emprestado. A média mundial está em US\$ 0.34 por US\$ 1. Essa baixa recuperação de crédito impacta diretamente os custos administrativos dos bancos, um dos componentes do *spread*¹. Com *spreads* altos, recessão econômica e a má administração financeira das famílias, a taxa de inadimplência no sistema bancário de crédito chega a 3.04%, o que representa R\$ 96.6 bilhões de um total de R\$ 3.168 trilhões concedidos (CHC Advocacia, 2019). O uso intensivo da tecnologia promove uma diminuição palpável nos custos, além de uma enorme democratização dos meios de pagamento

¹ Para mais informações, veja <https://www.infomoney.com.br/minhas-financas/spread-bancario-do-brasil-e-o-2o-mais-alto-do-mundo-entenda-por-que/>

e opções de investimento ao público em geral. É plausível que as *fintechs* tragam oportunidades de negócios mais atraentes para os brasileiros.

Segundo Lee e Shin (2018), o *Global Fintech Report* (PwC, 2016) indicou que 83% das IFs acreditam que vários aspectos do seu modelo de negócio estão em risco pelas *fintechs startups*, de modo que cada instituição precisa desenvolver habilidades que permitam a alavancagem e/ou investimento em tecnologia em ordem de se manterem competitivas. Além disso, Haddad e Hornuf (2018) apontam que quanto mais difícil é o acesso ao capital por parte das companhias, mais alto é o número de *startups* dentro de um país.

Por outro lado, a própria definição de “banco” implica atuar simultaneamente em três ramos de atividades: modificar as características de ativos e passivos financeiros, prover serviços de pagamentos, e coletar e processar informações (NAVARETTI et al., 2017). Modificar as características de ativos e passivos financeiros é principalmente realizado através da “maturity transformation”, isto é, o uso de financiamentos de curto prazo para garantir empréstimos de longo prazo. Essa função é essencial para qualquer sistema econômico, já que permite o financiamento de investimentos de longo prazo, e por consequência gera produtividade, enquanto que ao mesmo tempo resguarda os depositantes de choques de liquidez idiossincráticos. Dada sua função de prover liquidez aos consumidores, os bancos também estão bem estabelecidos como prestadores de serviços de pagamentos (NAVARETTI et al., 2017).

O estágio que as *startups* se encontram ainda é notadamente novo. Isso vem acompanhado de entraves na obtenção de dados mais desagregados e específicos sobre as companhias e seus derivativos. Em âmbito geral, Vives (2017) elencou, através de uma pesquisa na literatura, diversos impactos que as *fintechs* promovem na eficiência, estrutura de mercado bancária, estratégias dos incumbentes e entrantes, e estabilidade financeira. Contudo, ainda não existem trabalhos que busquem observar empiricamente o comportamento dos bancos tradicionais frente às *fintechs* no mercado brasileiro, o que promove a inovação do tema e sua relevância. Além disso, entender a postura que os bancos estão adotando e as novas possibilidades de serviços que as empresas de tecnologia promovem, é essencial para a tomada de decisão de governos, empresas e famílias, especialmente baseado na atual conjuntura recessiva experienciada pela economia do país.

Nesse sentido, esse trabalho buscou avaliar os possíveis impactos que a inserção das *fintechs* disseminou ao longo do mercado financeiro brasileiro através das diferentes estruturas de receitas, despesas e no desempenho das instituições. Nos Estados Unidos da América (EUA), Almanidis (2013) mostrou que as instituições financeiras sempre se preocuparam com a inovação tecnológica, contudo, a aquisição e adoção das novas tecnologias não se dá da mesma

forma para os bancos de diferentes tamanhos. Por isso, também foi de interesse averiguar quais os efeitos das *fintechs* para bancos com diferentes números de agências, uma vez que lidando com alternativas ao sistema tradicional, o número de agências se traduz em um medidor do tamanho do acesso que os bancos provêm, além de contabilizar implicitamente seu tamanho patrimonial. A base de dados utilizada foi a do if.data, do Banco Central do Brasil (BACEN), durante o período de março de 2010 até setembro de 2019. A base de dados apresenta periodicidade trimestral e sua estrutura é de painel. Com isso, foram empregados modelos econométricos de Efeito Fixo para avaliar os efeitos das *fintechs*.

Além dessa sessão, o trabalho está dividido em mais 5 partes, sendo a próxima uma análise exploratória da literatura em cima do contexto histórico que as *fintechs* se inseriram, sua estrutura regulamentária no Brasil e sua interação com o sistema bancário tradicional; a terceira explora a base de dados utilizada no trabalho e como ela foi manipulada, desde a filtragem até a caracterização das variáveis; a quarta apresenta a estratégia empírica utilizada, com os pressupostos necessários; a quinta traz os resultados encontrados, as limitações e a análise de robustez empregada; e por fim é apresentado a conclusão com as considerações finais do trabalho.

2. Revisão da literatura

2.1 Contexto histórico

Lee e Shin (2018) dão uma introdução acerca das inovações tecnológicas e financeiras. Eles apontam que a revolução da internet no início dos anos 1990 afetou profundamente os mercados financeiros, levando a diminuição maciça dos custos das transações. O avanço tecnológico impulsionado pela internet levou ao desenvolvimento das “finanças eletrônicas” – o *e-finance*². Em meados dos anos 2000, o aumento no número de usuários de *smartphones* facilitou o aumento das “finanças móveis”, tais como pagamentos e internet *banking* via celular. Com o desenvolvimento do *e-finance* e da tecnologia portátil dos celulares, a inovação das *fintechs* emergiu após a crise financeira mundial de 2008. Ela foi uma combinação de *e-finance*, internet, serviços digitais, mídias sociais, inteligência artificial, e *big data*.

A entrada das *fintechs* no mercado financeiro é discutida na literatura. Conforme aponta Philippon (2016), serviços financeiros ainda são custosos e inovações financeiras não entregaram benefícios significativos para os consumidores. Aditivo à discussão, a carência na entrada e competitividade no mercado financeiro têm sido um problema endêmico em décadas recentes. Nos EUA, o número de bancos e organizações bancárias caiu quase 30% entre 1988 e 1997, e a parcela de todos os ativos americanos aplicados nas 8 maiores organizações bancárias aumentou de 22.3% para 35.5%. Milhares de fusões e aquisições ocorreram nestes anos, incluindo megafusões entre instituições com mais de \$1 bilhão em ativos.

A crise global de 2008-2009 definiu o formato dos serviços financeiros e da tecnologia da informação que conhecemos atualmente, e agiu como catalisador no efeito das *fintechs*. Com a lacuna de financiamento instaurada no período pós crise, a desconfiança nas IFs formais, e reformas regulatórias como o “Dodd Frank Act” e o acordo de Basiléia III, as obrigações ligadas ao *compliance* das instituições aumentou significativamente (MANSILLA-FERNÁNDEZ, 2018). Consequentemente, isso gerou uma oportunidade para a entrada de empresas inovadoras e serviços mais baratos no mercado (GONZÁLEZ-PÁRAMO, 2017).

Nesse sentido, Lee e Shin (2018) ainda identificam as *fintechs startups* como as companhias que mais têm impulsionado as inovações nas áreas de pagamentos, *wealth management*, empréstimos, *crowdfunding*, mercado de capitais, e seguros, por incorrer em

² Segundo os autores, *e-finance* se refere a todas as formas de serviços financeiros, tais como *banking*, seguros, e bolsa de valores gerenciados por meios eletrônicos, incluindo a internet.

menores custos, alcancarem mais nichos de mercados, e prover serviços mais personalizados do que as instituições financeiras tradicionais. Navaretti et al. (2017) colocam que, diferente dos bancos, as informações utilizadas pelas *fintechs* é baseada em *big data* e não em um relacionamento de longo prazo entre os clientes e as IFs; o acesso aos serviços é descentralizado através das plataformas digitais; os riscos e maturidade dos investimentos são minimizados; e tomadores de empréstimos e empreendedores, ou oportunidades de investimentos e investidores são pareados diretamente.

Tememos, uma empresa suíça que desenvolve *softwares* para bancos e instituições financeiras, conduziu um estudo (TEMEMOS, 2019) para medir a capacidade de abertura de contas digitais de 60 bancos médios e representativos da América do Norte, Europa e Austrália em 2019. Pontos do relatório mostram que os maiores bancos norte-americanos lideram o ranking na adoção de vendas de produtos através de canais digitais; três quartos das contas pessoais podem ser abertas online; o celular é finalmente o carro chefe em relação ao uso do computador na abertura e utilização de todos os tipos de contas digitais, o que indica que a evolução desse segmento é constante.

Segundo o Radar Fintechlab de junho de 2019³, o Brasil conta com 529 empresas atualmente, sendo a habilidade de desagregar serviços uma grande vantagem das *startups*, uma vez que os consumidores estão começando a escolher serviços financeiros de uma variedade de *fintechs* ao invés de uma única instituição financeira (LEE e SHIN, 2018). De acordo com o relatório de Wardrop et al. (2016), em 2015 as plataformas de financiamento alternativo geraram um volume de mercado de US\$36.49 bilhões somados os países do continente americano, um aumento de 212% dos US\$11.68 bilhões em 2014. Os EUA são o carro chefe desse mercado, sendo na época responsável por 99% do volume mencionado. No Brasil, segundo os resultados do mesmo relatório, as plataformas digitais somaram US\$24.15 milhões em volume transacionado em 2015. Isso representa 222% de aumento em relação aos US\$7.51 milhões registrados em 2014. Em 2013 esse número era de US\$4.39 milhões.

Uma das empresas brasileiras precursoras nesse segmento e que mais se destacou em âmbito internacional é a Nubank, cujo escopo de negócios é do tipo intermediação financeira, onde ela oferece um cartão de crédito sem anuidade e com relacionamento 100% digital⁴. Recentemente a *fintech* lançou a opção de débito, onde todo o valor da conta fica automaticamente aplicado em títulos públicos e rendendo mais do que a poupança. Além disso,

³ Disponível em <https://fintechlab.com.br/index.php/2019/06/12/8a-edicao-do-radar-fintechlab-registra-mais-de-600-iniciativas/>

⁴ Para mais informações, acesse <https://analistamodelosdenegocios.com.br/modelo-de-negocio-do-nubank/>

o fato de não existirem tarifas ou cobranças nas transações financeiras, resulta em um grande atrativo de consumidores.

Carvalho (2020) em entrevista com Bruno Diniz (especialista em *fintechs* no Brasil) aponta que diante da entrada de novos *players* no segmento financeiro, os bancos estão tendo que se modernizar e mudar sua abordagem em virtude de reconquistar clientes. Soluções mais intuitivas, melhora na experiência de seus aplicativos e canais de atendimento, e até mesmo o lançamento de seus próprios bancos digitais – como o caso do Next, *fintech* do Bradesco – são exemplos da postura migratória que os bancos estão adotando. O autor ainda segue colocando que uma maior competição melhorará a prestação de serviços e fará com que as taxas cobradas diminuam.

Além disso, Carvalho (2020) ainda mostra que as *insurtechs* (*fintechs* que atuam no segmento de seguros) também já são realidade. Ela traz o exemplo de empresas que cobram seguro automobilístico baseado no quilômetro rodado, como o caso da americana Metromile, também outras que monitoram o veículo por meio de sensores e precificam o seguro baseado no comportamento do condutor ao dirigir, como a Smappi Car da Itália.

2.2 Regulamentação

No que tange a regulamentação das *fintechs*, a CHC Advocacia (2019) aponta que diversas espécies de *start ups* do ramo financeiro operam sem uma legislação específica que as regulamente. Um exemplo é o PayPal e o PagSeguro, que, por não possuírem uma legislação própria, atuam amparadas pelo campo da legalidade, da ilegalidade e da licitude, ou seja, uma vez que suas operações não são reguladas por lei, podem exercer suas funções em razão da liberdade individual. Além da liberdade de contratar e do campo da licitude, as empresas estão também sujeitas às normas gerais que regem a atividade empresarial, principalmente dispostas no Código Civil de 2002 e na Lei nº 6404/76, como coloca a CHC Advocacia (2019).

No relatório de estabilidade financeira de setembro de 2016 do BC⁵, a instituição reconhece a importância do emprego de novas tecnologias, contudo se mantém alerta na medida que as inovações possam impactar a solidez do sistema financeiro. Nesse sentido, o BC estabeleceu através da Portaria BCB nº 89.399, de 3 de junho de 2016, um grupo de trabalho interdepartamental cujo objetivo é elaborar estudos sobre inovações tecnológicas e seus potenciais impactos sobre o sistema financeiro.

⁵ Disponível em https://www.bcb.gov.br/htms/estabilidade/2016_09/refPub.pdf

Dentre os diversos setores explorados pelas *fintechs*, existem também os serviços prestados pelas plataformas de *Crowdfunding* e *Peer-to-peer lending* (P2P), os quais funcionam juntando investidores e tomadores de créditos. Em especial, a recente legislatura brasileira tomou um grande avanço regulamentando essas práticas e desvencilhando os serviços das instituições financeiras tradicionais.

Segundo a CROWDINVEST – a Associação Brasileira de Crowdfunding de Investimento⁶, uma parceria entre a associação e a Comissão de Valores Imobiliários (CVM) deu início a um regulamento próprio para o mercado brasileiro de *crowdfunding*, onde teve a submissão à consulta pública no segundo semestre de 2016 e posterior publicação em julho de 2017. A Instrução CVM nº 588, de 13 de julho de 2017⁷, segundo seu artigo primeiro, tem por objetivo assegurar a proteção dos investidores e possibilitar a captação pública por parte das plataformas digitais. As plataformas têm autorização para exercer a atividade de distribuição de ofertas públicas de valores mobiliários, realizadas com dispensa de registro.

Outro passo importante no avanço regulamentário do Brasil foi a adoção da Resolução nº 4.656, de 26 de abril de 2018⁸, que dispõe sobre a Sociedade de Crédito Direto (SCD) e sobre a Sociedade de Empréstimo entre Pessoas (SEP), isto é, *peer-to-peer* (P2P) *lending*. A SCD é considerada uma instituição financeira (IF) que tem por objetivo a realização de operações de empréstimo, de financiamento e de aquisição de direitos creditórios exclusivamente por meio de plataforma eletrônica, por meio de recursos financeiros que tenham como única origem capital próprio. A SEP é IF que atua nas operações de intermediação financeira, fornecendo empréstimos e financiamentos de recursos coletados dos credores e direcionados aos devedores, após negociação em plataforma eletrônica.

Carvalho (2020) traz a opinião de Bruno Diniz, especialista em *fintechs* no Brasil sobre o momento atual das companhias. Segundo Diniz, os avanços na regulamentação para 2020 são a nova infraestrutura de pagamentos instantâneos, baseada em *QR code* funcionando todos os dias, diferentemente da TED; a criação de um *Sandbox* Regulatório onde o regulador poderá monitorar *fintechs* com novos modelos de negócio que ainda não possuem legislação específica e, após análise, autorizar o seu funcionamento; e a regulamentação do Open Banking, que visa agilizar e tornar mais seguras a portabilidade dos dados bancários e histórico financeiro de um cliente de banco para outros bancos e *fintechs*, desde que autorizados por ele.

⁶ Para mais informações acesse <http://equity.org.br/equity-crowdfunding/>

⁷ Disponível em <http://www.cvm.gov.br/legislacao/instrucoes/inst588.html>

⁸ Disponível em https://www.bcb.gov.br/pre/normativos/busca/downloadNormativo.asp?arquivo=/Lists/Normativos/Attachments/50579/Res_4656_v1_O.pdf

2.3 *Fintechs* e o sistema bancário

A hipótese de que as *fintechs* podem afetar o sistema bancário tradicional vem sendo objeto de estudo na academia. Li et al. (2017) trouxeram a seguinte indagação: qual o impacto das *fintechs startups* de *digital banking funding* nos retornos das ações dos bancos tradicionais americanos. Para tanto, eles utilizaram uma amostra de 47 bancos de varejo dos EUA e seus respectivos retornos acionários entre 2010 a 2016, relacionando com o volume de dólares financiados e o número de negócios operacionalizados pelas *startups*, através de métodos de regressão com dados em painel. Seus resultados sugerem um relacionamento positivo entre o crescimento do financiamento das *fintechs* e os retornos contemporâneos das ações dos bancos.

Jagtiani e Lemieux (2018) buscaram responder se a expansão do acesso ao crédito promovido pela plataforma americana LendingClub, que atua no setor de *peer-to-peer lending* (P2P), alcançou áreas mal servidas pelos bancos tradicionais. Eles utilizaram dados contábeis da *startup* e dados do Y-14M, provido pelos bancos americanos, e constataram que em mercados muito concentrados e áreas que possuíam poucas filiais bancárias os consumidores fizeram uso da *fintech*. Encontraram também que a porção de empréstimos da plataforma aumentou em áreas onde a economia local não estava tendo um bom desempenho.

Seguindo a mesma linha, Dermine (2017) mostra como operações de P2P e *marketplace* podem afetar o sistema bancário. Segundo o autor, a capacidade das *fintechs* em lidar com a assimetria de informação e a divisão dos investimentos em pequenas parcelas, as quais permitem a diversificação, são pontos chaves na comparação com os bancos. Além disso, ele ainda chama a atenção que o atual ambiente econômico norte americano, com taxas de juros ultrabaixas, e a recuperação econômica do país, foram circunstâncias que propiciaram o crescimento dessa indústria.

Por outro lado, algumas funções desempenhadas por *fintechs*, como sistemas de pagamentos (como por exemplo Apple Pay e PayPal) ainda são sustentadas por bancos. Bancos perdem parte de sua margem, porém ainda mantém o relacionamento final com seus clientes, e por causa da eficiência desses novos serviços, eles expandem seu raio de atuação, se tornando nesse caso complementares às *fintechs* (NAVARETTI et al., 2017). Ainda, a cadeia produtiva dos bancos inclui muitos serviços e atividades interligadas e as *fintechs*, de modo geral, não apresentam um pacote de serviços muito cheio, se restringindo a prestação de apenas alguns serviços específicos. Os serviços agregados dos bancos provêm fortes economias de escala, e isso promove sua habilidade de concentrar tantos serviços em uma mesma IF (NAVARETTI et al., 2017).

Segundo Dyniewicz (2019) os bancos digitais têm avançado graças a seus aplicativos superiores na comparação com o dos bancos tradicionais e a várias isenções tarifárias. Por não terem despesas com agências, as *fintechs* conseguem oferecer contas gratuitas. A autora aponta que o banco digital alemão N26 calcula que seu custo operacional por cliente seja cerca de 15% do de um banco tradicional. Ela conta que quando as *fintechs* não oferecem gratuidade, elas explicam de forma detalhada ao cliente o que ele está pagando. No entanto só isso pode não ser suficiente. Para atingir a consolidação é necessário escala, que por sua vez está ligado a oferta de mais tipos de produtos. No caso dos bancos tradicionais, o crédito costuma ser uma das principais fontes de receita, o que justifica a entrada das *fintechs* nesse segmento (DYNIEWICZ, 2019).

Conforme Magnus (2018), o fato de as IFs serem referência em transformação digital e novas tecnologias é devido ao aumento na concorrência trazida pelas *fintechs* e pela globalização dos serviços. Segundo o autor, um dos grandes problemas enfrentados pelos bancos é que muitas instituições ainda operam com *mainframes* gigantes carregados de dados e geridos em Cobol (linguagem legada de programação), sendo o primeiro passo em direção à digitalização a busca por alternativas que substituam essas *databases*.

3. Descrição dos dados

Considerando o estágio gestativo que as *startups* ainda se encontram, em especial no Brasil, a quantidade de dados disponíveis é limitada, mais ainda no que diz respeito a dados macroeconômicos desagregados. Dessa forma, a estratégia empírica recaiu nos dados financeiros das instituições bancárias, contidos no sistema de dados do BACEN, o if.data⁹. Dentro desse conjunto, a base de dados de interesse é composta por instituições independentes (IIs) representadas por instituições financeiras e demais instituições autorizadas a funcionar pelo BACEN apresentadas separadamente por personalidade jurídica (CNPJ), em nível não consolidado. As informações coletadas foram o demonstrativo de resultado, o resumo e as contas do ativo do balanço de pagamentos e estão descritas individualmente no apêndice deste trabalho.

A base de dados apresenta periodicidade trimestral, e foi restrita ao primeiro trimestre de 2010 até o terceiro trimestre de 2019, gerando um painel de dados desbalanceado com 39 períodos de tempo, onde cada um contém em média 1,738 instituições, visto que o número de IFs pode variar de acordo com o período observado¹⁰. Dessa forma o painel conta com 67,786 observações.

Dado o objetivo de avaliar o impacto das *fintechs* no sistema bancário, foram extraídas 7 variáveis de interesse. A primeira diz respeito à “Renda de Operações de Crédito”, que engloba as rendas de créditos vinculados a operações adquiridas em cessão; os lucros em operações de venda ou de transferência de ativos financeiros; recuperação de créditos baixados como prejuízo; rendas de créditos decorrentes de contratos de exportação adquiridos; rendas de crédito por avais e fianças honrados; rendas de repasse interfinanceiros; despesas de cessão de créditos decorrentes de contratos de exportação; despesas de cessão de operações de crédito; e prejuízos em operações de venda ou de transferência de ativos financeiros.

A segunda variável é “Rendas de Prestação de Serviços”, na qual faz parte as rendas de garantias prestadas. Depois tem-se as “Rendas de Tarifas Bancárias” que incorpora as rendas de pacotes de serviço pessoa física; serviços prioritários pessoa física; serviços diferenciados pessoa física; serviços especiais pessoa física; e tarifas bancárias pessoa jurídica¹¹. A quarta

⁹ Disponível em <https://www3.bcb.gov.br/ifdata/>

¹⁰ O número de IFs diminui do período mais antigo para o período mais recente, sendo que no primeiro trimestre de 2010 tem-se 2,008 instituições e no terceiro trimestre de 2019 existem apenas 1,472 IFs.

¹¹ A diretriz que define as normas de aplicação das Tarifas e Serviços bancários é a Resolução nº 3.919 do BACEN, disponível em https://www.bcb.gov.br/pre/normativos/res/2010/pdf/res_3919_v4_P.pdf

variável é “Despesas de Pessoal”, que inclui despesas com honorários, benefícios, encargos sociais, proventos, treinamento, remuneração de estagiários e impostos e contribuições sobre salários. Em seguida tem-se “Despesas Administrativas”, com recuperação de encargos e despesas; despesas de amortização; despesas de depreciação, e despesas de administração de fundos e programas sociais.

Por fim, com base nas variáveis disponíveis, foram criados dois medidores de desempenho das instituições bancárias, isto é, a variável de “Retorno sobre Ativo” (ROA), que mostra como a IF é rentável em relação ao seu ativo total; e “Retorno sobre o Patrimônio Líquido” (ROE), que mostra com que eficácia uma instituição utiliza sua base de capital.¹²

3.1 Filtragem

O próximo passo foi a filtragem da amostra. No banco de dados há uma variável que identifica o tipo de consolidado bancário que cada IF faz parte. Foram mantidas as IFs que atuam essencialmente como bancos, retirando-se as cooperativas, bancos de desenvolvimento, instituições não bancárias atuantes no mercado de crédito e de capitais e instituições de pagamento. Dessa forma excluímos da análise grande parte das *fintechs* de empréstimos, pagamentos e de investimentos. Embora reste alguns bancos que podem ser considerados bancos digitais, como o Banco Inter, Banco Neon e Banco Agibank, eles adotaram uma postura migratória em direção à digitalização de seus serviços, o que é exatamente o comportamento esperado que seja adotado pelas instituições bancárias em prol de se manterem competitivas frente ao avanço das *startups*.

Foram excluídas também da análise as IFs que apresentavam renda negativa e/ou despesa positiva e em seguida foi aplicado o logaritmo dessas variáveis¹³. Em seguida, foram retiradas as observações ausentes dessas variáveis. Com isso, o banco de dados se reduziu para em média 92 instituições por período, totalizando um painel desbalanceado de 3,594 observações.

¹² Para mais informações, veja <https://www.treasy.com.br/blog/roa-retorno-sobre-o-ativo/#E-qual-a-diferenca-entre-ROA-e-ROE>

¹³ A aplicação da função logarítmica permite um relacionamento não linear e por consequência, mais generalizado entre as variáveis; minimiza a heterocedasticidade por ter retornos marginais decrescentes, além de promover uma distribuição mais próxima da normal nos termos de erro; medidas macroeconômicas geralmente apresentam tendências de crescimento exponenciais e a transformação logarítmica tende a linearizá-las; e, por fim, o logaritmo facilita a interpretação dos coeficientes dos modelos.

3.2 Caracterização das variáveis

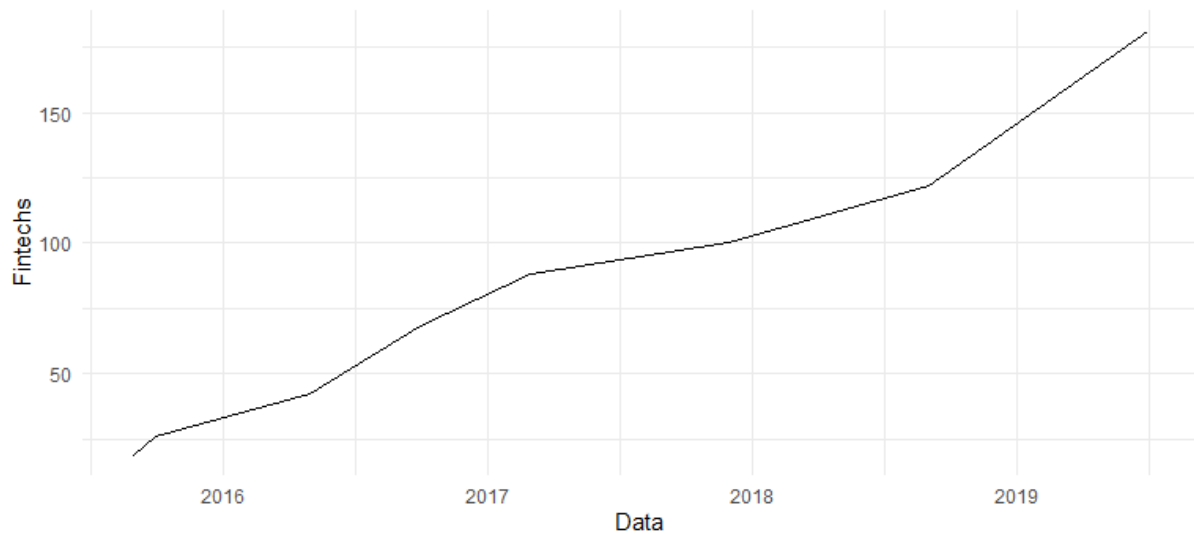
Fintech por definição, identifica empresas que trazem inovações digitais e tecnológicas nos modelos de negócio do setor financeiro (PHILIPPON, 2016). Embora muitas *startups* e IFs se enquadrem nesse quesito – até porque os investimentos do setor bancário em tecnologia somaram R\$ 118.7 bilhões entre 2012-2017, com média anual de R\$ 19.8 bilhões, segundo dados da Febraban¹⁴ – é complicado observar um divisor de águas claro entre quais empresas financeiras são consideradas *fintechs* e quais não são. No Brasil, algumas instituições já nasceram com o gene tecnológico presente em seu DNA, como é o caso do Nubank. Contudo, o mercado não é estático e empresas como o Agibank e Banco Inter já estão promovendo mudanças nessa direção. Grandes *players* brasileiros também estão lançando suas próprias empresas de tecnologia financeira. Alguns exemplos são o Banco Next, banco totalmente digital do Bradesco; BB Digital, banco digital do Banco do Brasil; SuperDigital, do Santander.

A falta de dados claros em cima desse segmento também é outro entrave na busca por definições específicas das *startups*. Com isso, a caracterização das *fintechs* recaiu em definir variáveis *dummy* para designar sua presença no mercado financeiro brasileiro. A primeira variável *dummy* foi estabelecida na data de lançamento do cartão de crédito sem tarifas do Nubank em abril de 2014. Como os dados são trimestrais, a *dummy* assume valor um após junho de 2014 até o final do período em análise e valor zero antes. O lançamento abre as portas para esse tipo de serviço no Brasil. O gráfico apresentado na figura 1 a seguir mostra a evolução dos serviços digitais disponibilizados desde agosto de 2015.

¹⁴ Disponível em

<https://cmsportal.febraban.org.br/Arquivos/documentos/PDF/Inova%C3%A7%C3%A3o%20e%20Competi%C3%A7%C3%A3o%20-%20Novos%20Caminhos%20para%20Redu%C3%A7%C3%A3o%20dos%20Spreads%20Banc%C3%A1rios.PDF>

Figura 1. Evolução dos serviços digitais no Brasil



Fonte: Radar Fintechlab.

O gráfico gerado com os dados do Radar Fintechlab¹⁵ mostra a evolução do número de *fintechs* de pagamentos, multisserviços e bancos digitais no Brasil, desde agosto de 2015 até junho de 2019. Como pode ser observado, o número vem em uma crescente constante, totalizando no período mais recente 151 instituições de pagamento, 12 IFs de multisserviços e 18 bancos digitais, sendo um reflexo da presença das *startups* no país.

A segunda variável *dummy* criada assume o valor um após ser publicada a Resolução nº 4.656, de 26 de abril de 2018¹⁶, que dispõe sobre a Sociedade de Empréstimo entre Pessoas (SEP), isto é, *peer-to-peer* (P2P) *lending*. As startups de P2P atuam no mercado de crédito juntando investidores e empreendedores por meio de uma plataforma digital. Dessa forma, promovem uma opção mais rentável para ambas as partes, isto é, o credor recebe juros mais altos do que receberia em uma aplicação bancária convencional e o tomador paga juros mais baixos do que pagaria em um empréstimo tradicional, de modo a minimizar o *spread* da operação de crédito. O interesse com essa variável foi avaliar os possíveis impactos na “Renda de Operações de Crédito” dos bancos tradicionais.¹⁷

¹⁵ Disponível em <https://fintechlab.com.br/>

¹⁶ Disponível em https://www.bcb.gov.br/pre/normativos/busca/downloadNormativo.asp?arquivo=/Lists/Normativos/Attachments/50579/Res_4656_v1_O.pdf

¹⁷ Embora as operações de P2P existissem antes de serem regulamentadas em 2018, os bancos eram intermediários nessas operações, angariando assim uma fatia dos lucros gerados por elas. A variável *dummy* da Resolução é indicada, uma vez que não há mais a necessidade da presença dos bancos, e assim não há o repasse dos custos para os clientes. Pode-se esperar um comportamento migratório por parte dos consumidores demandantes de crédito, tanto pessoas físicas como jurídicas.

Além das variáveis *dummy*, também estão presentes no modelo variáveis de controle macroeconômicas e de controle bancário. As variáveis de controle macroeconômicas variam apenas no tempo. Entre elas serão utilizadas o logaritmo da taxa de crescimento do índice de produção industrial¹⁸, extraído da base de dados da Organização para a Cooperação e Desenvolvimento Econômico (OCDE); o logaritmo da taxa de câmbio; a razão dos depósitos compulsórios totais pelo volume de crédito total; uma medida de inflação dada pelo IGP-M; a taxa de juros representada pelo CDI; a taxa percentual de endividamento das famílias com o Sistema Financeiro Nacional em relação à renda acumulada dos últimos doze meses; e o grau de concentração do mercado bancário, medido pelo índice de Herfindahl–Hirschman (HHI), calculado com base nos dados do if.data. Conforme colocam Ely et al. (2019), essas variáveis controlam mudanças temporais do ambiente macroeconômico e do mercado financeiro experienciadas durante o período avaliado. Com exceção do índice de produção industrial e do HHI, todas as variáveis foram extraídas do banco de dados do BACEN¹⁹.

As variáveis bancárias variam no tempo e entre as instituições. Estão presentes o logaritmo do total de ativos das IFs; a razão entre os ativos líquidos pelo total de ativos; o grau de alavancagem; a razão entre o total de depósitos e o total de ativos; a razão do total de despesas pelos empréstimos líquidos; e a razão entre o total de empréstimos e o total de ativos. A tabela 1 abaixo traz as estatísticas descritivas das variáveis.

¹⁸ A produção industrial se refere ao produto de setores industriais como mineração, manufatura, eletricidade, gás e vapor, e ar condicionado. O indicador é medido com base em um período de referência (IDX2015) que expressa a mudança no volume de produção industrial gerado (OECD, 2020).

¹⁹ Disponível em

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

Tabela 1. Estatísticas descritivas

Variáveis de interesse	Média	Mínimo	Máximo	Desvio Padrão
Renda crédito	1,287,366	4	48,941,992	4,641,327
Renda serviço	226,852	1	10,417,674	861,639.1
Renda tarifas	118,943	1	5,023,581	470,111.1
Despesas pessoal	286,498	1	11,746,480	1,147,825
Despesas adm.	319,112	149	9,003,755	1,036,226
ROA	0.0026	-0.6637	0.3913	0.0276
ROE	0.0238	-57.2273	53.5692	0.9078
Variáveis de controle macroeconômico				
Ln(Δ Prod. Industrial)	-0.0031	-0.0355	0.0293	0.0160
Ln(Câmbio)	0.1556	0.1131	0.2309	0.0332
Razão Compulsórios	0.9319	0.4667	1.3795	0.3129
IGP-M	0.4925	-0.9	1.2733	0.4533
CDI	9.7815	6.0033	14.1333	2.5976
Endividamento	42.9122	36.1700	46.6033	2.5004
HHI	0.1020	0.0484	0.1287	0.0214
Variáveis de controle bancárias				
Ln(Ativo)	15.3371	9.6430	21.1264	2.197
Razão de liquidez	0.0190	-0.3073	2.5035	0.0509
Alavancagem	8.0679	-10.6368	153.6471	7.6170
Razão de depósitos	0.6462	0	1.2493	0.2157
Razão de custos	-0.6546	-46.3101	277.5661	4.7841
Empréstimos/ativos	0.0580	-0.2520	6.4466	0.1180

Nota: A tabela apresenta as estatísticas descritivas para a amostra de 3,558 bancos sendo omitidos 36 valores ausentes. Apesar das variáveis de Renda e Despesa terem sido utilizadas na forma logarítmica, sua estatística descritiva foi exibida em nível em prol de facilitar a interpretação e seus valores estão em mil unidades monetárias. O painel é trimestral compreendendo o primeiro trimestre de 2010 até o terceiro trimestre de 2019.

Da tabela 1 acima, pode-se destacar alguns pontos. Todos os valores máximos das variáveis de Renda e Despesa ficaram restritos a algum dos cinco maiores bancos brasileiros. Já os valores mínimos variam para mais bancos, e todos possuem um número médio de agências inferior a 20. A grande amplitude das variáveis, em especial do ROE, mostra que os bancos apresentam características bem diferentes quanto a rentabilidade. Por outro lado, a razão Empréstimos/ativos apesar de apresentar uma variância relativamente alta, na média, os bancos brasileiros não são tão endividados, apenas 5%. A Razão de liquidez também traça esse caminho, mostrando que na média, os bancos brasileiros tem condições de honrar seus débitos sem ajuda externa. É interessante notar que a taxa de endividamento das famílias tem seu ponto mínimo em no primeiro trimestre de 2010, talvez em função da política expansionista adotada na época, dois anos após a crise do *subprime* americano; e seu ponto máximo em março de 2015, momento em que o país começa a sentir de forma mais aguda os efeitos da recessão mundial.

4. Estratégia empírica

O objetivo principal do trabalho é avaliar os possíveis impactos que a entrada das *fintechs* no setor bancário pode acarretar. Em específico, avaliar se há alguma mudança no comportamento das séries de interesse. Nesse sentido, a estrutura de painel dos dados permite estimar uma variedade de modelos econométricos que meçam o efeito médio da variável *dummy* nas demais variáveis. Contudo, cada modelo contém pressupostos estatísticos específicos que precisam ser atendidos em prol de não se estimar regressões espúrias. Por exemplo, existe uma classe de modelos que partem do pressuposto que o termo de erro em cada período de tempo é não correlacionado com as variáveis explicativas no mesmo período de tempo. Em certas aplicações de dados em painel esse pressuposto é muito forte (WOOLDRIDGE, p. 281, 2010).

A decisão de se aprimorar tecnologicamente e se voltar à digitalização não é tomada aleatoriamente, e sim baseada em diversos fatores bancários e macroeconômicos. Além disso, conforme apontado por Almanidis (2013), a indústria bancária é caracterizada pelo seu grande número de instituições que apresentam características diferentes entre si. A heterogeneidade surge em virtude das diferenças nas oportunidades de negócios que cada instituição experiencia, nas estratégias de crédito, acessibilidade aos mercados monetários de curto prazo, exposição ao risco, investimentos em tecnologia, e vários outros fatores que são essencialmente ligados ao tamanho dos bancos. Inerentemente, nem todas as fontes de heterogeneidade entre as firmas podem ser controladas pelas covariadas e, conseqüentemente, se tornam não observadas.

Essas diferenças não observadas, por sua vez, quando não controladas, ficam presentes no termo de erro, trazendo o problema de variável omitida, que enviesam os resultados dos estimadores. Uma das maneiras de corrigir esse problema é o Modelo de Efeitos Fixos, tido como “padrão ouro” na literatura, contendo, contudo, algumas limitações (SCHURER e YONG, 2012a).

4.1 Pressupostos do modelo de Efeito Fixo

O modelo a ser estimado consiste na seguinte equação:

$$y_{it} = D. fin_t \beta_0 + CTRL. MACRO_t \beta_1 + CTRL. BANK_{it} \beta_2 + D. TEMPO_t \beta_3 + c_i + u_{it} \quad (1)$$

onde y_{it} são as variáveis de interesse; $D.fin_t$ é a variável *dummy* referente à entrada das *fintechs* no mercado financeiro; $CTRL.MACRO_t$ são as variáveis de controle macroeconômicas; $CTRL.BANK_{it}$ são as variáveis de controle bancárias; $D.TEMPO_t$ são variáveis *dummy* de ano, introduzidas com o intuito de controlar mudanças temporais não captadas pelas demais covariadas; c_i é o componente individual não observado de cada IF; e u_{it} é o termo de erro idiossincrático.

Conforme apontado por Wooldridge (p.286, 2010), quase sempre faz sentido tratar os efeitos não observados, c_i , como sorteios aleatórios da população, juntamente com y_{it} e as demais covariadas do modelo, uma vez que essa abordagem é adequada pela perspectiva de variável omitida. O primeiro pressuposto que deve ser atendido é o de exogeneidade estrita. Assumindo $x_{it} = \beta_0 x_{t1} + \dots + \beta_k x_{tk}$ como sendo o conjunto de covariadas do modelo, colocado em termos de expectativas condicionais, conforme Wooldridge (p. 287, 2010), o pressuposto pode ser descrito como

$$E(y_{it}|x_{i1}, x_{i2}, \dots, x_{iT}, c_i) = E(y_{it}|x_{it}, c_i) = x_{it} \cdot + c_i, \quad (2)$$

para $t = 1, 2, \dots, T$. A primeira igualdade indica que, uma vez que x_{it} e c_i estão controlados, x_{is} não tem efeito parcial em y_{it} para $s \neq t$. Quando o pressuposto apresentado em (2) é válido, $\{x_{it}: t = 1, 2, \dots, T\}$ é estritamente exógeno condicional ao efeito não observado c_i .

O pressuposto de estrita exogeneidade restringe como o valor esperado de y_{it} pode depender nas variáveis explicativas em outros períodos de tempo, mas é mais razoável do que exogeneidade estrita sem condicionar no efeito não observado. Posto do ponto de vista do erro idiossincrático, u_{it} , o pressuposto obedece a seguinte restrição:

$$E(u_{it}|x_{i1}, x_{i2}, \dots, x_{iT}, c_i) = 0. \quad (3)$$

A expressão indica que as variáveis explicativas em cada período de tempo são não correlacionadas com o termo de erro idiossincrático em cada período de tempo, $E(x'_{is}u_{it}) = 0$. Esse pressuposto é muito mais forte do que assumir apenas zero correlação contemporânea, $E(x'_{it}u_{it}) = 0$ (WOOLDRIDGE, p.288, 2010). Esse é um dos motivos pelo qual não podemos incluir no modelo de Efeitos Fixos defasagens da variável dependente dentro do conjunto de covariadas, conforme apontado por Ely et al. (2019).

Fazendo um comparativo com o modelo de Efeitos Aleatórios que permite que c_i seja qualquer função de x_i , o modelo de Efeitos Fixos agrega robustez à análise. No entanto, sem outras restrições, não é possível incluir fatores constantes no tempo em x_{it} , isto é, se c_i pode ser arbitrariamente correlacionado com cada elemento de x_{it} , não há como distinguir os efeitos dos observáveis constantes no tempo dos não observáveis constantes no tempo c_i . No caso de

firmas bancárias, fatores como missão, valores, segmento de atuação, e outras características que não tendam a se alterar com o passar do tempo, não podem ser incluídas em x_{it} . Contudo, o interesse recai apenas em variáveis explicativas variantes no tempo, e não em variáveis fixas, tornando o modelo adequado (WOOLDRIDGE, p. 302, 2010).

Para tornar válido o primeiro pressuposto, é necessário que c_i seja eliminado. A transformação do Modelo de Efeitos Fixos é feita primeiro através da média das variáveis variantes no tempo, $\bar{y}_i = \bar{x}_i \cdot + c_i + \bar{u}_i$ ²⁰ e em seguida subtrai-se $y_{it} = x_{it} \cdot + c_i + u_{it}$, obtendo-se o modelo transformado:

$$\dot{y}_{it} = \dot{x}_{it} \cdot + \dot{u}_{it}, \quad t = 1, 2, \dots, T. \quad (4)$$

Os fatores fixos no tempo são excluídos da equação, e o Modelo de Efeitos Fixos pode ser estimado conforme um modelo de Mínimos Quadrados Ordinários Empilhados comum, o qual deve ser assintoticamente bem comportado e obedecer as condições de posto das variáveis explicativas, isto é, $posto(\sum_{t=1}^T E(\dot{x}'_{it} \dot{x}_{it})) = posto[E(\ddot{X}_i \ddot{X}_i)] = K$. A condição de posto cheio mostra que se x_{it} contenha algum elemento que não varie no tempo para qualquer i , então o elemento correspondente em \dot{x}_{it} é idêntico a zero para todo t , de modo que não são permitidas variáveis constantes no tempo, a não ser quando interagidas com variáveis variantes no tempo, como *dummies* de ano.

O último pressuposto garante que o Modelo de Efeitos Fixos é eficiente, ou seja, $E(u_i u_i' | \ddot{X}_i) = \sigma_u^2 I_T$. Essa condição implica que os erros idiossincráticos, u_{it} , têm variação constante através de t e são serialmente não correlacionados (WOOLDRIDGE, p. 304, 2010). No entanto, essa hipótese por vezes não é respeitada em função da estrutura da base de dados. A intenção de explicitamente incluir o efeito comum no modelo é para se controlar a fonte de uma possível correlação, embora isso não exclua a heterocedasticidade do modelo, e sim centre a média condicional apropriadamente (GREENE, p. 426, 2012). Dessa forma, conforme é usual na literatura, foi adotado a matriz de covariância robusta dos parâmetros para efeitos fixos, de acordo com o método sugerido por White (WHITE, 1980, 1984; ARELLANO, 1987). O método assume que não há correlação dentro dos grupos, isto é, entre as firmas, e sim entre os períodos de tempo.

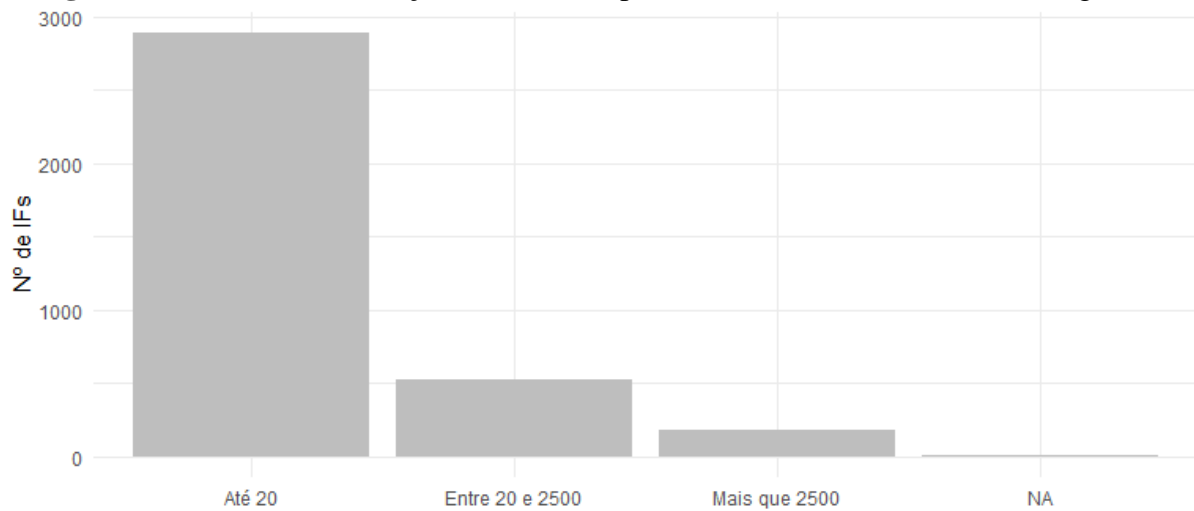
²⁰ $\bar{y}_i = T^{-1} \sum_{t=1}^T y_{it}$; $\bar{x}_i = T^{-1} \sum_{t=1}^T x_{it}$; $\bar{u}_i = T^{-1} \sum_{t=1}^T u_{it}$.

5. Resultados

É uma prática padrão adotada por reguladores para analisar os bancos, separá-los em categorias diferentes de tamanho. Por exemplo, o “Federal Deposit Insurance Corporation” (FDIC) divide as IFs em quatro grupos diferentes baseado no valor de mercado de seus ativos totais (ALMANIDIS, 2013). Ainda segundo o autor, é crucial distinguir e separar os bancos em categorias de tamanho adequadas quando se investigando a existência de tecnologias heterogêneas e medindo a performance.

O tamanho dos ativos é uma variável comumente utilizada na literatura bancária para designar bancos a determinados grupos, no entanto a lista de variáveis que podem ser utilizadas para distinguir os bancos é enorme. (ALMANIDIS, 2013). No caso dos dados disponíveis no if.data, existem diversos tipos de segmentação adotada pelo BACEN, contudo se adotou uma diferenciação em termos de acesso aos bancos por parte dos consumidores, ou seja, o número de agências. Como aponta Martins (2012), apenas os maiores bancos brasileiros estão instalados fisicamente em áreas de menor concentração populacional, fora dos grandes centros. Com isso, a maioria das instituições financeiras focam suas operações em áreas mais ricas e desenvolvidas, fazendo a estrutura do setor bancário altamente dispersa geograficamente.

Assim, os modelos a seguir apontam os resultados para 4 tipos de interações com as variáveis *dummy*: (1) Bancos “pequenos”, que têm em média entre uma até 20 agências; (2) Bancos “médios”, com 20 a 2500 agências; (3) Bancos “grandes”, com mais de 2500 agências (apenas os 5 maiores bancos brasileiros); e (4) Todos as IFs com uma agência ou mais. O fato de se utilizar o número de agências para definir o “tamanho” das instituições é porque serve como uma medida de acesso dos consumidores aos bancos, sem a necessidade de um meio digital e ainda mensura implicitamente seu tamanho patrimonial. A figura a seguir mostra um histograma com a subdivisão da amostra para o painel de dados.

Figura 2. Número de instituições financeiras por intervalo de número médio de agências

Fonte: elaboração própria.

A amostra completa, com todos os bancos, possui 3,594 observações. As subamostras divididas para o período de março de 2010 até setembro de 2019, contaram com 2,853 observações de IFs com até 20 agências; entre 20 e 2500 agências são 559; com mais de 2500 agências bancárias têm-se 180; e por fim 2 observações ausentes sobre o número de agências na amostra. O número total de bancos da amostra foi 139, dos quais 116 têm até 20 agências; 16 apresentam 20 até 2500 agências; 5 bancos com mais de 2500 agências; e 2 bancos com observações ausentes. A lista completa dos bancos analisados pode ser encontrada no apêndice.

De acordo com a variável de interesse a ser avaliada, foi adotada uma estratégia diferente. A primeira variável é a de Rendas de Crédito. Para avaliar os efeitos das *fintechs* no mercado de crédito, faz mais sentido utilizar a interação das variáveis *dummies* de número médio de agências com a variável *dummy* de P2P, pois essa atividade impacta diretamente no mercado creditício, uma vez que permite uma fonte alternativa de financiamento aos agentes. Já as demais variáveis de Rendas de Serviços e Tarifas bancárias; Despesas Administrativas e de Pessoal; e Performance, com o ROA e ROE, que não são ligadas para o mercado de crédito diretamente, e sim na atividade bancária como um todo, tendem a sofrer os impactos das *startups* desde sua chegada e gradual expansão. Nesse caso é mais indicado utilizar a interação das variáveis *dummies* com a variável *dummy* de Início das *fintechs*, dada no lançamento do cartão de crédito do Nubank.

A tabela 2 abaixo resume os resultados encontrados para a variável $\ln(\text{Rendas crédito})$, que representa as rendas oriundas de operações de crédito por parte das instituições bancárias.

Os quatro modelos diferem apenas na interação da variável *dummy* de P2P²¹ com a variável *dummy* indicativa do número médio de agências presente para as instituições.

Tabela 2. Resultados da variável Renda de operações de crédito

	<i>Variável de interesse:</i>			
	Ln(Renda crédito)			
	(1)	(2)	(3)	(4)
Dummy P2P*Pequenos	0.128** (0.050)	-	-	-
Dummy P2P*Médios	-	-0.175*** (0.057)	-	-
Dummy P2P*Grandes	-	-	0.037 (0.059)	-
Dummy P2P*Todos	-	-	-	-0.859*** (0.180)
Ln(Prod. Industrial)	-11.936*** (1.043)	-11.936*** (1.043)	-11.943*** (1.047)	-11.945*** (1.042)
Ln(Câmbio)	1.237*** (0.315)	1.237*** (0.315)	1.235*** (0.315)	1.233*** (0.315)
Razão Compulsórios	1.508 (1.414)	1.508 (1.414)	1.492 (1.415)	1.485 (1.412)
IGP-M	-0.040 (0.031)	-0.040 (0.031)	-0.039 (0.031)	-0.039 (0.031)
CDI	-0.127*** (0.020)	-0.127*** (0.020)	-0.127*** (0.020)	-0.127*** (0.020)
Endividamento	-0.006 (0.023)	-0.006 (0.023)	-0.006 (0.023)	-0.006 (0.023)
HHI	0.912 (0.837)	0.913 (0.837)	0.909 (0.836)	0.908 (0.837)
Ln(Ativo)	1.009*** (0.054)	1.010*** (0.054)	1.007*** (0.054)	1.008*** (0.054)
Razão de liquidez	-0.061 (1.312)	-0.059 (1.312)	-0.034 (1.314)	-0.063 (1.317)
Alavancagem	-0.009** (0.005)	-0.009** (0.004)	-0.009** (0.004)	-0.009* (0.004)
Razão de depósitos	0.342 (0.215)	0.340 (0.215)	0.354* (0.214)	0.389* (0.216)
Razão de custos	0.004 (0.004)	0.004 (0.004)	0.004 (0.004)	0.004 (0.004)
Empréstimos/ativos	1.629* (0.913)	1.629* (0.913)	1.620* (0.914)	1.629* (0.911)
Dummy P2P	0.092 (0.070)	0.221*** (0.064)	0.193*** (0.064)	1.045*** (0.189)
Observações	3,341	3,341	3,341	3,341
R ²	0.356	0.356	0.355	0.357
R ² ajustado	0.323	0.323	0.322	0.324
Estatística F (g.l. = 24; 3180)	73.094***	73.189***	72.906***	73.451***

Nota: Modelo de efeitos fixos individuais com variáveis *dummy* de ano (omitidas por razão de concisão). Os desvios padrão estão entre parênteses. Níveis de significância representados por *p<0.1; **p<0.05; ***p<0.01.

Os bancos que têm um acesso físico mais restrito ao público por terem menos agências, tiveram um aumento de 0.12%, enquanto que os bancos com 20 até 2500 agências tiveram uma diminuição de 0.17% em suas rendas de operações de crédito, os bancos grandes apresentaram aumento, mas o resultado não é estatisticamente significativo. A amostra completa, com todos os bancos tiveram uma redução de 0.85%.

Pode-se fazer 4 inferências acima desses resultados. 1º os bancos pequenos estão adentrando mercados pouco explorados pelos bancos em geral e podem já estar adotando uma

²¹ A *dummy* assume o valor um no primeiro período disponível após a publicação a Resolução nº 4.656, de 26 de abril de 2018, que dispõe sobre a Sociedade de Empréstimo entre Pessoas (SEP), i.e., *peer-to-peer* (P2P) *lending*.

postura migratória na direção de serviços digitais; 2º os bancos médios ainda estão em uma fase mais conturbada onde soma-se a transição para serviços mais modernos e despesas com investimentos em tecnologia; 3º os bancos grandes ainda possuem uma economia de escala desproporcional em relação aos demais, e um poder de mercado que dificulta a perda de receita em operações de crédito, estritamente ligadas as taxas de *spread* praticadas por essas instituições; e 4º no geral, os bancos com 20 até 2500 agências estão puxando os resultados para baixo, uma vez que estão concorrendo entre si, entre os bancos pequenos e com as *fintechs* e, com isso, despontam no quesito investimentos que necessariamente são altos.

O próximo passo da análise é em cima das variáveis de Rendas de Serviços e Tarifas e Despesas com Pessoal e Administrativas, e sua interação com a variável *dummy* de entrada das *fintechs* no mercado. Nesse caso, porém, sob o ponto de vista das variáveis de interesse não há uma relação clara com uma concessão jurídica específica, como no caso da Resolução sobre as *startups* de P2P. Então a estratégia adotada foi a utilização da *dummy* de lançamento do cartão de crédito sem tarifas do Nubank²², que incorpora a entrada das *fintechs* no mercado financeiro brasileiro, como foi detalhado na seção dos dados. A tabela 3 apresenta os resultados encontrados.

Em relação a $\text{Ln}(\text{Renda serviço})$ e $\text{Ln}(\text{Renda tarifas})$, a subamostra de bancos com até 20 agências apresentou um efeito positivo e significativo estatisticamente após a entrada das *fintechs*. A $\text{Ln}(\text{Renda serviço})$, teve um aumento de 0.20%. A renda de serviços engloba apenas as rendas de garantias prestadas que constituam receita efetiva da instituição, no período. Um exemplo desse tipo de renda são as “Cartas Fiança”, no qual a instituição dá a garantia de pagamento em caso de eventual inadimplência²³. Já a renda de tarifas aumentou um pouco menos, 0.12% em média durante o período após o ingresso das *startups*.

Avaliando os bancos médios, os dois tipos de rendas foram significativas estatisticamente e negativas, ou seja, os bancos médios tiveram um resultado menor do que os bancos pequenos e grandes nesses quesitos após a implementação da variável *dummy*. Já os bancos grandes não apresentaram valores significativos, além de terem sinais opostos em relação aos dois tipos de renda. Observando a amostra completa, isto é, com todos os bancos, percebe-se que o resultado, semelhante aos bancos médios, é significativo e negativo, porém em uma proporção maior.

²² A data de lançamento do cartão de crédito sem tarifas do Nubank ocorreu em abril de 2014, sendo que a variável *dummy* recebeu o valor no próximo período disponível em diante, isto é, a partir de junho de 2014 até o fim do período avaliado.

²³ Para mais informações, acesse <https://www.sunoresearch.com.br/artigos/carta-fianca/>.

Tabela 3. Resultados das variáveis de Renda e Despesas

	<i>Variáveis de interesse:</i>															
	Ln(Renda serviço)				Ln(Renda tarifas)				Ln(Despesas pessoal)				Ln(Despesas adm.)			
	(1)	(2)	(3)	(4)	(1)	(2)	(3)	(4)	(1)	(2)	(3)	(4)	(1)	(2)	(3)	(4)
Dummy Fintechs *Pequenos	0.204*** (0.062)	-	-	-	0.120* (0.063)	-	-	-	0.127*** (0.040)	-	-	-	0.039 (0.036)	-	-	-
Dummy Fintechs *Médios	-	-0.190*** (0.062)	-	-	-	-0.148** (0.067)	-	-	-	-0.089** (0.043)	-	-	-	0.034 (0.038)	-	-
Dummy Fintechs *Grandes	-	-	-0.165** (0.071)	-	-	-	0.001 (0.067)	-	-	-	-0.183*** (0.057)	-	-	-	-0.222*** (0.057)	-
Dummy Fintechs *Todos	-	-	-	-2.641*** (0.564)	-	-	-	-2.129*** (0.496)	-	-	-	-3.766*** (0.621)	-	-	-	-3.370*** (0.429)
Ln(Ativo)	0.977*** (0.088)	0.976*** (0.088)	0.971*** (0.088)	1.003*** (0.088)	0.867*** (0.080)	0.867*** (0.080)	0.863*** (0.080)	0.889*** (0.080)	0.396*** (0.055)	0.395*** (0.055)	0.393*** (0.054)	0.439*** (0.053)	0.565*** (0.041)	0.563*** (0.041)	0.565*** (0.041)	0.606*** (0.040)
Razão de liquidez	-1.971 (1.683)	-1.958 (1.684)	-1.843 (1.675)	-1.711 (1.672)	1.278 (1.812)	1.263 (1.814)	1.356 (1.808)	1.459 (1.798)	-1.577** (0.799)	-1.550* (0.799)	-1.499* (0.796)	-1.312* (0.724)	0.036 (0.711)	0.082 (0.711)	0.055 (0.709)	0.224 (0.652)
Alavancagem	0.002 (0.005)	0.002 (0.005)	0.002 (0.005)	-0.002 (0.005)	-0.002 (0.005)	-0.002 (0.005)	-0.002 (0.005)	-0.006 (0.005)	0.002 (0.005)	0.002 (0.005)	0.002 (0.005)	-0.004 (0.004)	0.001 (0.004)	0.001 (0.004)	0.001 (0.004)	-0.005* (0.003)
Razão de depósitos	-0.428 (0.317)	-0.423 (0.317)	-0.415 (0.317)	-0.428 (0.314)	0.592** (0.242)	0.593** (0.242)	0.602** (0.242)	0.588** (0.241)	0.224 (0.153)	0.229 (0.153)	0.230 (0.153)	0.210 (0.141)	0.157 (0.123)	0.162 (0.123)	0.155 (0.123)	0.139 (0.116)
Razão de custos	-0.004*** (0.001)	-0.004*** (0.001)	-0.004*** (0.001)	-0.004*** (0.001)	0.001 (0.002)	0.001 (0.002)	0.001 (0.002)	0.001 (0.002)	-0.002** (0.001)	-0.002** (0.001)	-0.002** (0.001)	-0.001** (0.001)	-0.003*** (0.001)	-0.003*** (0.001)	-0.003*** (0.001)	-0.002*** (0.001)
Empréstimos/ativos	1.992** (0.816)	1.988** (0.816)	1.945** (0.814)	1.864** (0.786)	0.696 (0.902)	0.702 (0.902)	0.668 (0.901)	0.604 (0.875)	1.279** (0.620)	1.270** (0.620)	1.250** (0.620)	1.135** (0.546)	1.120* (0.672)	1.103 (0.673)	1.112* (0.672)	1.009* (0.607)
Dummy Fintechs	-0.278** (0.130)	-0.086 (0.129)	-0.109 (0.128)	2.497*** (0.576)	0.025 (0.121)	0.144 (0.116)	0.120 (0.115)	2.227*** (0.507)	-0.124 (0.087)	-0.009 (0.085)	-0.014 (0.085)	3.703*** (0.648)	-0.062 (0.065)	-0.037 (0.062)	-0.020 (0.061)	3.304*** (0.453)
Observações	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341
R ²	0.161	0.160	0.160	0.172	0.189	0.189	0.189	0.198	0.267	0.266	0.266	0.332	0.324	0.324	0.326	0.402
R ² ajustado	0.118	0.118	0.117	0.131	0.149	0.149	0.148	0.157	0.230	0.229	0.229	0.298	0.290	0.290	0.292	0.371
Estatística F (g.l. = 24; 3180)	25.362***	25.292***	25.169***	27.604***	30.951***	30.973***	30.860***	32.628***	48.193***	48.010***	48.077***	65.777***	63.601***	63.582***	64.030***	88.901***

Nota: Modelo de efeitos fixos individuais com variáveis *dummy* de ano e variáveis de controle macroeconômico omitidas por razão de concisão. Os desvios padrão estão entre parênteses. Níveis de significância representados por *p<0.1; **p<0.05; ***p<0.01.

A filtragem dos dados buscou eximir as empresas que fossem *fintechs*, pelo menos desde sua criação, como o caso do Nubank, em prol de avaliar apenas os efeitos nos bancos tradicionais. A renda de serviços reduz para todos os bancos com exceção dos pequenos, visto que ambientes alternativos que promovem garantias similares, como as *fintechs* ou cooperativas, são mais atrativos. Já a renda de tarifas, reduz principalmente para os bancos médios, uma vez que os grandes potencialmente tem clientes mais fiéis, principalmente os institucionais.

Outro canal, conforme apontam Budhathoki e Rai (2019), é que existem duas linhas sobre as receitas provenientes de fontes externas aos juros, como o caso das tarifas e serviços: por um lado os bancos impulsionam as receitas e se previnem das flutuações da taxa de juros, por outro, quando o engajamento em fontes alternativas aos juros é excessivo, o volume dos fundos disponíveis para empréstimos tradicionais é diminuído. No caso brasileiro, a queda gradativa na taxa básica de juros desde agosto de 2015 pode ser um fator preponderante na manutenção das fontes alternativas de receita dos bancos, especialmente aqueles que tem uma capacidade creditícia menor.

No que diz respeito às despesas dos bancos, percebe-se que os bancos médios, isto é, aqueles com um número médio de agências entre 20 e 2500, parecem estar reduzindo principalmente as despesas com pessoal, enquanto os bancos grandes, com mais de 2500 agências, também estão focando nas despesas administrativas. Os bancos pequenos, com até 20 agências, como parecem estar crescendo, naturalmente aumentam as despesas em relação aos outros, porém estão mirando nas despesas de pessoal ao invés das administrativas.

Invariavelmente a tecnologia, não só as promovidas estritamente pelas *fintechs*, absorve muita mão de obra, e o setor bancário passa a ser cada vez mais intensivo em capital. A diminuição nos gastos com funcionários, cortes de pessoal e redução no número de agências compõe a trajetória de queda das despesas dos bancos. No caso dos bancos com até 20 agências, levando em consideração seu tamanho financeiro, o custo marginal de um único empregado é relativamente maior do que o de um banco de grande porte, somado a isso o espaço de crescimento mais vertiginoso que esses bancos apresentam, explicam o aumento nas despesas com pessoal.

Tabela 4. Resultados das variáveis de Desempenho

	<i>Variáveis de interesse:</i>							
	ROA				ROE			
	(1)	(2)	(3)	(4)	(1)	(2)	(3)	(4)
Dummy Fintechs*Pequenos	-0.0001 (0.001)	-	-	-	0.003 (0.010)	-	-	-
Dummy Fintechs *Médios	-	-0.0002 (0.001)	-	-	-	-0.018** (0.008)	-	-
Dummy Fintechs *Grandes	-	-	0.001 (0.001)	-	-	-	0.041** (0.017)	-
Dummy Fintechs *Todos	-	-	-	0.023*** (0.004)	-	-	-	0.253 (0.176)
Ln(Prod. Industrial)	-0.072** (0.029)	-0.072** (0.029)	-0.072** (0.029)	-0.072** (0.029)	-0.519** (0.224)	-0.518** (0.224)	-0.519** (0.224)	-0.519** (0.226)
Ln(Câmbio)	0.021** (0.011)	0.021** (0.011)	0.021** (0.011)	0.021** (0.011)	0.157** (0.071)	0.157** (0.071)	0.156** (0.071)	0.159** (0.071)
Razão Compulsórios	0.015 (0.059)	0.015 (0.059)	0.015 (0.059)	0.016 (0.059)	0.302 (0.416)	0.303 (0.415)	0.298 (0.415)	0.309 (0.416)
IGP-M	0.0001 (0.001)	0.0001 (0.001)	0.0001 (0.001)	0.0001 (0.001)	-0.001 (0.008)	-0.001 (0.008)	-0.001 (0.008)	-0.001 (0.008)
CDI	-0.0003 (0.001)	-0.0003 (0.001)	-0.0003 (0.001)	-0.0003 (0.001)	-0.007 (0.006)	-0.007 (0.006)	-0.007 (0.006)	-0.007 (0.006)
Endividamento	-0.001 (0.001)	-0.001 (0.001)	-0.001 (0.001)	-0.001 (0.001)	-0.0004 (0.006)	-0.0004 (0.006)	-0.0003 (0.006)	-0.0004 (0.006)
HHI	0.027 (0.027)	0.027 (0.027)	0.027 (0.027)	0.027 (0.027)	-0.118 (0.219)	-0.117 (0.219)	-0.119 (0.218)	-0.119 (0.215)
Ln(Ativo)	0.006*** (0.002)	0.006*** (0.002)	0.006*** (0.002)	0.006*** (0.002)	0.107*** (0.022)	0.107*** (0.022)	0.107*** (0.022)	0.104*** (0.021)
Razão de liquidez	0.689*** (0.122)	0.689*** (0.122)	0.689*** (0.122)	0.688*** (0.121)	1.658** (0.684)	1.648** (0.684)	1.660** (0.682)	1.647** (0.678)
Alavancagem	-0.00004 (0.0002)	-0.00004 (0.0002)	-0.00004 (0.0002)	-0.00000 (0.0002)	-0.021*** (0.006)	-0.021*** (0.006)	-0.021*** (0.006)	-0.020*** (0.005)
Razão de depósitos	-0.014 (0.011)	-0.014 (0.011)	-0.014 (0.011)	-0.013 (0.011)	0.046 (0.053)	0.045 (0.053)	0.047 (0.053)	0.048 (0.053)
Razão de custos	-0.0001 (0.0001)	-0.0001 (0.0001)	-0.0001 (0.0001)	-0.0001 (0.0001)	0.001** (0.0003)	0.001** (0.0003)	0.001** (0.0003)	0.001** (0.0003)
Empréstimos/ativos	-0.258*** (0.047)	-0.258*** (0.047)	-0.258*** (0.047)	-0.257*** (0.047)	-0.608** (0.263)	-0.604** (0.263)	-0.609** (0.262)	-0.601** (0.260)
Dummy Fintechs	-0.001 (0.002)	-0.001 (0.002)	-0.001 (0.002)	-0.024*** (0.005)	-0.006 (0.014)	-0.001 (0.013)	-0.006 (0.013)	-0.254 (0.177)
Observações	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341
R ²	0.236	0.236	0.236	0.239	0.276	0.276	0.276	0.281
R ² ajustado	0.198	0.198	0.198	0.200	0.239	0.240	0.240	0.244
Estatística F (g.l. = 24; 3180)	41.023***	41.023***	41.027***	41.533***	50.439***	50.523***	50.596***	51.684***

Nota: Modelo de efeitos fixos individuais com variáveis *dummy* de ano (omitidas por razão de concisão). Os desvios padrão estão entre parênteses. Níveis de significância representados por *p<0.1; **p<0.05; ***p<0.01.

A tabela 4 buscou avaliar variáveis que expressassem o desempenho das IFs – Retorno sobre ativos (ROA) e Retorno sobre o patrimônio líquido (ROE). Tiveram aumento o ROA da amostra completa, e o ROE dos 5 maiores bancos brasileiros²⁴. O ROE dos bancos médios diminuiu na média, após o ingresso das *startups*, e o dos bancos grandes aumenta, enquanto os

²⁴ Itaú, Bradesco, Banco do Brasil, Santander e Caixa Econômica.

bancos pequenos e digitais parecem que ainda não estão tendo aumento significativo na lucratividade. A curva de competição pode ser afetada com isso, deixando uma distância maior entre bancos grandes e médios em termos de rentabilidade sobre o patrimônio e crescimento. Conforme coloca Tecles e Tabak (2010), bancos grandes são melhores em se adaptar a novas estruturas de mercado, com os níveis de eficiência mais altos.

Além disso, Silva e Lucinda (2017) mostram que há evidências de poder de mercado, pelo menos entre os bancos de varejo, que podem estar relacionados com os custos de transição entre os bancos. Como colocam os autores, exemplos disso são as “contas universitárias”, que reduzem as tarifas dos clientes que são estudantes universitários; a agressividade que os bancos buscando o direito de gerir contas de pagamento de instituições públicas; e a exigência de que empregados recebam seus salários apenas por uma conta bancária definida pelo empregador.

5.1 Limitações

O trabalho se propôs a avaliar os possíveis impactos da entrada das *fintechs* no mercado financeiro. Contudo, o termo é amplo e engloba diversos aspectos que muitas vezes se misturam com os serviços já ofertados pelas instituições tradicionais, tornando o problema de identificação no maior limitante. Até o momento não há uma base de dados que faça uma distinção clara das empresas de tecnologia e das demais. Agrega-se a isso o pequeno número de empresas em relação a todo sistema financeiro, dado que é um serviço ainda recente no Brasil.

A base de dados do if.data permitiu avaliar alguns pontos específicos, como operações de crédito, rendas e despesas, e o desempenho das IFs. Embora não haja um ponto definido da entrada das *fintechs*, fez-se uso de duas variáveis *dummy* que indicassem um possível aumento no número de *start ups* ingressantes: a data de lançamento do cartão sem tarifas do Nubank em abril de 2014 e a publicação da Resolução nº 4.656, de 26 de abril de 2018, acerca das operações de P2P por parte das *fintechs*. Embora tenha havido de fato um aumento constante no número dessas empresas a partir da data de lançamento do cartão, conforme detalhado na seção de dados, esse aumento foi pouco expressivo. Além do mais, outros fatores corroboraram para essa entrada, como o avanço tecnológico e a maior maturação desses serviços em outros países.

Já a segunda variável *dummy* é mais adequada, em especial no que diz respeito às operações de crédito. Visto que a Resolução permitiu que as operações de P2P fossem efetuadas apenas pelas *fintechs*, sem a necessidade de um intermediário bancário tradicional, os impactos ficaram restritos a um seguimento mais específico, o que melhora a qualidade da inferência. No

entanto, só se aplica às operações de crédito, o que inviabiliza utilizá-la para as demais variáveis de interesse.

5.2 Análise de robustez

Além da estrutura e natureza dos dados utilizados, que por si só já trazem inferências sobre o tipo de modelo mais adequado, há também testes de robustez que possibilitam julgar a escolha do modelo mais apropriado, bem como sua melhor especificação.

A análise econométrica de dados em painel tem se apoiado no “error component regression model” (modelo de regressão de composição do erro), o qual tem sua origem na literatura da estatística e biometria. Grande parte dessa literatura foca em painéis completos e balanceados, contudo, aplicações empíricas não raro encontram observações ausentes ou painéis incompletos (BALTAGI et al., 2001). Como foi observado na base de dados, o painel utilizado não é completo, de modo que o primeiro passo da análise de robustez foi avaliar o nível em que ele está desbalanceado. O método proposto por Ahrens e Pincus (1981) prevê duas medidas de não balanceamento, γ e μ .²⁵ Quanto mais próximo o valor estiver de um, mais balanceado o painel está. O resultado encontrado foi $\gamma = 0.4818$ e $\mu = 0.8380$ indicando que o painel é moderadamente desbalanceado, inspirando cautela nos resultados.

Conforme colocado anteriormente, é esperado um comportamento individual e não observado de cada IF presente no painel de dados, contudo, foi avaliado através de um teste F se há efeito individual e/ou de tempo baseado na comparação entre os modelos de Mínimos Quadrados Ordinários Empilhados e de Efeitos Fixos. O resultado observado para todos os modelos de cada variável de interesse foi em favor do modelo de Efeitos Fixos, como esperado. Além disso, o teste do Multiplicador de Lagrange de King e Wu (1997) também apresentou o mesmo resultado. Os testes indicam que há correlação temporal e serial entre os indivíduos.

Outro ponto a ser levado em consideração é que, em geral, uma razão para se utilizar o modelo de Efeito Fixo é que os parâmetros nos regressores que não são completamente colineares com os efeitos não observados podem ser estimados com menos perigo de se incorrer em viés de endogeneidade. Contudo, essa vantagem traz uma possibilidade potencialmente alta de perda de eficiência (BALTAGI, 2015, p. 629). Conforme Wooldridge (2010, p. 326), nos

²⁵ Considerando o modelo de efeitos individuais $y_{ij} = \mu + \alpha_i + e_{ij}$ ($i = 1, \dots, m$); $j = 1, \dots, n_i$), $N = \sum n_i$, com μ fixo, e_{ij} independentemente $N(0, \sigma^2)$ distribuído e α_i independentemente $N(0, \sigma_\alpha^2)$ distribuído (efeitos aleatórios) ou fixos mas desconhecidos, com condição de reparametrização $\sum \alpha_i = 0$ (efeitos fixos); e $\bar{n} = 1/m \sum n_i$, tem-se $\gamma(N) = m/\bar{n} \sum 1/n_i$ e $\mu(N) = 1/m \sum \left(\frac{n_i}{N}\right)^2$.

casos em que as variáveis chave em x_t não variam muito no tempo, modelos de Efeito Fixo podem levar a estimativas imprecisas. Pode ser que modelos de Efeitos Aleatórios meçam mais corretamente os parâmetros populacionais. Dessa forma, o próximo passo da análise de robustez foi o teste de endogeneidade de Hausman (1978)²⁶, que é baseado na diferença dos vetores dos coeficientes dos modelos de Efeito Fixo e de Efeitos Aleatórios e indica qual modelo é o mais apropriado. No apêndice a tabela 5 resume o teste.

Visto que algumas variáveis divergem sobre qual modelo é o mais adequado, foram estimadas regressões com Efeitos Aleatórios em prol de comparar os resultados encontrados. Os modelos também apresentam medidas de robustez dos parâmetros e constam no apêndice do trabalho. A tabela 6 traz os resultados para a variável de Renda com operações de crédito. Comparando apenas os coeficientes das interações do número de agências dos bancos com a variável *dummy* de P2P, percebe-se que os resultados são similares aos dos modelos de Efeito Fixo. O teste de Hausman indicou que a especificação mais adequada é a de Efeito Fixo no caso do modelo (1) que apresenta a interação com os bancos pequenos; e modelo de Efeitos Aleatórios no caso dos demais. Já o modelo (2), que conta com a *dummy* de bancos com o número médio de agências, apresentou um resultado semelhante e significativo estatisticamente. A tabela 7 no apêndice apresenta o modelo de Efeitos Aleatórios para as variáveis de Renda e Despesa. Segundo o teste de Hausman esse modelo é o mais indicado para as variáveis de interesse em questão. Mais uma vez, quando comparados os dois modelos, os resultados são muito próximos. Na análise das variáveis de desempenho, ROA e ROE, embora o teste de Hausman tenha apontado o modelo de Efeito Fixo como o ideal, os resultados seguiram a mesma linha.

Todos os modelos, quando comparados entre sua especificação, se Efeito Fixo ou Efeitos Aleatórios, apresentaram resultados muito próximos, o que é um bom indicativo de robustez. No entanto, como constatado no teste de balanceamento dos dados, o número de observações ausentes na amostra é um entrave na busca pela melhor especificação.

²⁶ Teste também conhecido como teste de Durbin-Wu-Hausman. A metodologia do modelo de Efeitos Aleatórios e a metodologia do teste de Hausman pode ser encontrada em Wooldridge (2010).

6. Conclusão

O trabalho buscou avaliar os impactos que as *fintechs* impõe ao sistema bancário tradicional no Brasil. O período de análise é trimestral e compreendeu março de 2010 até setembro de 2019. Conforme a seção de dados, a base contida no if.data tem a estrutura de painel o que permitiu a utilização de um modelo econométrico de Efeito Fixo na estimação dos resultados.

O primeiro passo da análise consistiu em estabelecer quais bancos fariam parte da amostra. Após definidas as variáveis de interesse, foi feita uma filtragem das IFs de acordo com o tipo de consolidado financeiro a que elas pertencem, sendo excluídas aquelas que não atuam essencialmente como bancos, e aquelas que apresentavam renda negativa e/ou despesa positiva. Em seguida foram definidas as duas variáveis *dummies* de caracterização das *fintechs*, sendo a primeira estabelecida na data de lançamento do cartão de crédito sem tarifas do Nubank em abril de 2014, e a segunda na publicação da Resolução nº 4.656, de 26 de abril de 2018, que dispõe sobre as operações de *Peer-to-peer lending* (P2P).

Além dessa filtragem, a análise foi subdividida para 4 segmentações de acordo com o número médio de agências das IFs, sendo (1) Bancos “pequenos”, que têm em média entre uma até 20 agências; (2) Bancos “médios”, com 20 a 2500 agências; (3) Bancos “grandes”, com mais de 2500 agências (apenas os 5 maiores bancos brasileiros); e (4) Todos as IFs com uma agência ou mais. Essa subdivisão permitiu avaliar os impactos de acordo com o acesso físico dos clientes a esses bancos, já que umas das premissas básicas das *fintechs* é o acesso puramente digital. Além disso, essa subdivisão também incorpora implicitamente o patrimônio dos bancos, sendo também uma medida do tamanho financeiro das instituições.

Como explicado na seção de resultados, as duas variáveis *dummies* criadas foram designadas de acordo com a variável de interesse, sendo a variável *dummy* de P2P voltada para a variável de renda de crédito, e a *dummy* de ingresso das *fintechs*, para as demais. Os resultados do modelo de Efeito Fixo para a variável de renda de operações de crédito mostraram que os bancos pequenos estão adentrando mercados pouco explorados pelos bancos em geral e podem já estar adotando uma postura migratória na direção dos serviços digitais, como é o caso do Banco Inter. Os bancos médios ainda estão em uma fase mais conturbada onde soma-se a transição para serviços mais modernos e despesas com investimentos em tecnologia. Já os bancos grandes ainda possuem uma economia de escala desproporcional em relação aos demais,

e um poder de mercado que dificulta a perda de receita em operações de crédito, estritamente ligadas as taxas de *spread* praticadas por essas instituições.

Em relação as variáveis de rendas de serviços e tarifas, e despesas com serviços e tarifas dos bancos, onde se utilizou a *dummy* de ingresso das *fintechs*, pode-se concluir que a Ln(Renda serviço), teve um aumento de 0.20%. Já a renda de tarifas aumentou um pouco menos, 0.12% em média durante o período após o ingresso das *startups*. Avaliando os bancos médios, se observa um resultado menor do que os bancos pequenos e grandes nesses quesitos. A renda de serviços reduz para todos os bancos com exceção dos pequenos, visto que ambientes alternativos que promovem garantias similares, como as *fintechs* ou cooperativas, são mais atrativos. Já a renda de tarifas, reduz principalmente para os bancos médios, uma vez que os grandes potencialmente tem clientes mais fiéis, principalmente os institucionais.

No que diz respeito às despesas dos bancos, percebe-se que os bancos médios parecem estar reduzindo principalmente as despesas com pessoal, enquanto os bancos grandes também estão focando nas despesas administrativas. Os bancos pequenos, como parecem estar crescendo, naturalmente aumentam as despesas em relação aos outros, porém estão mirando nas despesas de pessoal ao invés das administrativas.

Invariavelmente a tecnologia, não só as promovidas estritamente pelas *fintechs*, absorve muita mão de obra, e o setor bancário passa a ser cada vez mais intensivo em capital. A diminuição nos gastos com funcionários, cortes de pessoal e redução no número de agências compõe a trajetória de queda das despesas dos bancos. No caso dos bancos com até 20 agências, levando em consideração seu tamanho financeiro, o custo marginal de um único empregado é relativamente maior do que o de um banco de grande porte, somado a isso o espaço de crescimento mais vertiginoso que esses bancos apresentam, explicam o aumento nas despesas com pessoal.

O último ponto de análise foi em relação ao desempenho das instituições bancárias. Tiveram aumento o ROA da amostra completa, e o ROE dos 5 maiores bancos brasileiros. O ROE dos bancos médios diminuiu na média, após o ingresso das *startups*, e o dos bancos grandes aumenta, enquanto os bancos pequenos e digitais parecem que ainda não estão tendo aumento significativo na lucratividade. A curva de competição pode ser afetada com isso, deixando uma distância maior entre bancos grandes e médios em termos de rentabilidade sobre o patrimônio e crescimento.

Até o presente momento, não foi identificado na literatura uma abordagem empírica sobre os impactos das *fintechs* no sistema bancário brasileiro. Poder inferir sobre o comportamento de resposta dos bancos frente as *startups*, pode ajudar na promoção do sistema

financeiro pelos agentes reguladores, dada a sua importância para a saúde econômica do país e, por sua vez, proporcionar um ambiente de maior competição, que tende a trazer maiores benefícios para os consumidores.

Conforme detalhado na seção de limitações, pode-se destacar o problema ligado a disponibilidade de dados específicos sobre as *fintechs*, o que por sua vez torna o problema de identificação das *startups* no maior limitante. Trabalhos futuros ficam incumbidos de aprimorar os resultados, tanto através de dados mais acurados, quanto através de estratégias de identificação mais precisas, que permitam avaliar os efeitos da entrada das *startups* no mercado, e como isso afeta a estrutura de concorrência no setor.

Referências

- AAKER, David A.; KELLER, Kevin Lane. Consumer Evaluations of Brand Extensions. **Journal of Marketing**, v. 54, n. 1, p. 27, 1990.
- AHRENS, H.; PINCUS, R. On Two Measures of Unbalancedness in a One-Way Model and Their Relation to Efficiency. **Biometrical Journal**, v. 23, n. 3, p. 227–235, 1981.
- ALMANIDIS, P. Accounting for heterogeneous technologies in the banking industry: a time-varying stochastic frontier model with threshold effects. **Journal of Productivity Analysis**, v. 39, n. 2, p. 191–205, abr. 2013.
- ARELLANO, M. Computing Robust Standard Errors for Within-groups Estimators: PRACTITIONERS' CORNER. **Oxford Bulletin of Economics and Statistics**, v. 49, n. 4, p. 431–434, nov. 1987.
- AZEVEDO, P. F.; RIBEIRO, P.; RODRIGUES, G. Credit portability and spreads: Evidence in the Brazilian market. **Journal of Economics and Business**, v. 106, p. 105844, nov. 2019.
- BALTAGI, B. H. (ED.). **The Oxford handbook of panel data**. Oxford: New York: Oxford University Press, 2015.
- BARCZYK, R. The Business Cycle and Cycles in The Banking Sector in The Polish Economy in The Years 2000–2017. **Folia Oeconomica Stetinensia**, v. Volume 18: Issue 2, p. 106–120, 31 dez. 2018.
- BOND, S. R. Dynamic panel data models: a guide to micro data methods and practice. **Portuguese Economic Journal**, p. 141-162, 2002.
- BUDHATHOKI, P. B.; RAI, C. K. The Effect of Specific Factors on Bank Profitability: Evidence from Nepalese Banks. **Journal of Economics and Business**, v. 3, n. 1, p. 9, 30 mar. 2020.
- CHC Advocacia. **Como são regulamentadas as Fintechs no Brasil?** Mar. 2019. Disponível em: <<https://chcadvocacia.adv.br/blog/fintechs/>>. Acesso em: 17 de out. 2019.
- CARVALHO, P. Especialista responde 11 perguntas sobre o fenômeno fintech. **Estado de Minas**. Economia. Fev. 2020. Disponível em <https://www.em.com.br/app/noticia/economia/2020/02/02/internas_economia,1118820/especialista-responde-11-perguntas-sobre-o-fenomeno-fintech.shtml> Acesso em 07 fev. 2020.
- DERMINE, Jean. Digital Disruption and Bank Lending. **European Economy – Banks, Regulation, and the Real Sector**, Ano 3, Assunto 2, p. 63-76, 2017.
- DYNIWICZ, L. Revolução digital muda a cara dos bancos. **Estadão**. Economia & Negócios. Jul. 2019. Disponível em <<https://economia.estadao.com.br/noticias/geral,revolucao-digital-muda-a-cara-dos-bancos,70002920888>> Acesso em 07 fev. 2020.

ELY, Regis A; TABAK, Benjamin M; TEIXEIRA, Anderson M. Heterogeneous effects of the implementation of macroprudential policies on bank risk. **Munich Personal RePEc Archive**, n. 94546. p. 56, 2019.

GAI, Keke; QIU, Meikang; SUN, Xiaotong. A survey on FinTech. **Journal of Network and Computer Applications**, v. 103, p. 262–273, 2018.

GOMBER, Peter; KOCH, Jascha-Alexander; SIERING, Michael. Digital Finance and FinTech: current research and future research directions. **Journal of Business Economics**, v. 87, n. 5, p. 537–580, 2017.

GONZÁLEZ-PÁRAMO, J.M. Financial innovation in the digital age: Challenges for regulation and competition. **Revista de Estabilidad Financiera**, v.32, p. 9-37, 2017.

HADDAD, Christian; HORNUF, Lars. The emergence of the global fintech market: economic and technological determinants. **Small Business Economics**, v. 53, n. 1, p. 81–105, 2019.

HAUSMAN, J. A. Specification Tests in Econometrics. **Econometrica**, v. 46, n. 6, p. 1251, nov. 1978.

JAGTIANI, Julapa; LEMIEUX, Catharine. Do fintech lenders penetrate areas that are underserved by traditional banks? **Journal of Economics and Business**, v. 100, p. 43–54, 2018.

JHA, C. K. Financial Reforms and Corruption: Evidence using GMM Estimation. **International Review of Economics & Finance**, v. 62, p. 66–78, jul. 2019.

LEE, In; SHIN, Yong Jae. Fintech: Ecosystem, business models, investment decisions, and challenges. **Business Horizons**, v. 61, n. 1, p. 35–46, 2018.

LI, Yinqiao; SPIGT, Renée; SWINKELS, Laurens. The impact of FinTech start-ups on incumbent retail banks' share prices. **Financial Innovation**, v. 3, n. 1, p. 26, 2017.

MAGNUS, T. Transformação digital nos bancos: evolução nos serviços financeiros. **Transformação Digital**. Economia. Jul. 2018. Disponível em <<https://transformacaodigital.com/transformacao-digital-nos-bancos-evolucao-nos-servicos-financeiros/>> Acesso em 07 fev. 2020.

MANSILLA-FERNÁNDEZ, José Manuel. Fintech and Banking. Friends or Foes? Institutions. **European Economy – Banks, Regulation, and the Real Sector**, Ano 3, Assunto 2, p. 41-50, 2017.

MARTINS, B. Local Market Structure and Bank Competition: evidence from the Brazilian auto loan market. Working Paper Series, Banco Central do Brasil n. 299, p. 37, nov. 2012.

MORI, Rogério. UM NOVO CORTE DE JUROS? **Agroanalysis**, p. 11–12, jul. 2019.

NAVARETTI, G. B. et al. Fintech and Banking. Friends or Foes? **European Economy – Banks, Regulation, and the Real Sector**, Ano 3, Assunto 2, p. 9-30, 2017.

OECD, Industrial production (indicator). doi: 10.1787/39121c55-en. Acesso em: 10 jan. 2020.

PHILIPPON, Thomas. **The FinTech Opportunity**. Cambridge, MA: National Bureau of Economic Research, 2016. Disponível em: <<http://www.nber.org/papers/w22476.pdf>>. Acesso em: 9 jul. 2019.

PwC. **Blurred lines: How FinTech is shaping financial services**. Mar. 2016. Disponível em <<https://www.pwc.de/de/newsletter/finanzdienstleistung/assets/insurance-inside-ausgabe-4-maerz-2016.pdf>>.

SCHURER, S.; YONG, J. ‘Personality, Well-being and the Marginal Utility of Income: What Can We Learn from Random Coefficient Models?’ **Health, Economics and Data Group**. Working Paper, University of York, 2012. Disponível em <http://www.york.ac.uk/res/herc/documents/wp/12_01.pdf>, acessado em 4 abr. 2020.

SILVA, M. O.; LUCINDA, C. R. Switching costs and the extent of potential competition in Brazilian banking. **EconomiA**, v. 18, n. 1, p. 117–128, jan. 2017.

SWAMY, P. A. V. B.; ARORA, S. S. The Exact Finite Sample Properties of the Estimators of Coefficients in the Error Components Regression Models. **Econometrica**, v. 40, n. 2, p. 261, mar. 1972.

TECLES, P. L.; TABAK, B. M. Determinants of bank efficiency: The case of Brazil. **European Journal of Operational Research**, v. 207, n. 3, p. 1587–1598, dez. 2010.

TEMEMOS. **2019 State of Digital Sales in Banking - Annual Report**. Abr. 2019. Disponível em <<http://avoka.com>> Acesso em 20 de fev. 2020.

VIVES, X. The Impact of Fintech on Banking. **European Economy – Banks, Regulation, and the Real Sector**, Ano 3, Assunto 2, p. 97-105, 2017.

WARDROP, Robert; ROSENBERG, Robert; ZHANG, Bryan; ZIEGLER, Tania; SQUIRE, Rob; BURTON, John; HERNADEZ, Eduardo Jr. Arenas; GARVEY, Kieran. **Cambridge Centre for Alternative Finance**. Breaking New Ground: The Americas Alternative Finance Benchmarking Report. p. 80, 2016.

WHITE, H. A Heteroskedasticity-Consistent Covariance Matrix Estimator and a Direct Test for Heteroskedasticity. **Econometrica**, v. 48, n. 4, p. 817, maio 1980.

WOOLDRIDGE, J. M. **Econometric analysis of cross section and panel data**. 2nd ed. Cambridge, Mass: MIT Press, 2010.

Apêndice

Tabela 5. Instituições Individuais – demonstrativo de resultado (DRE)

Instituição financeira	Tipo de Controle – TC
Código	Tipo de Instituição – TI
Conglomerado	Cidade
Conglomerado Financeiro	Unidade Federativa – UF
Conglomerado Prudencial	Data
Tipo de Consolidado Bancário – TCB	
Resultado de Intermediação Financeira	
Receitas de Intermediação Financeira	Rendas de Operações de Crédito (a1) Rendas de Operações de Arrendamento Mercantil (a2) Rendas de Operações com TVM (a3) Rendas de Operações com Instrumentos Financeiros Derivativos (a4) Resultado de Operações de Câmbio (a5) Rendas de Aplicações Compulsórias (a6) Receitas de Intermediação Financeira (a) = (a1) + (a2) + (a3) + (a4) + (a5) + (a6)
Despesas de Intermediação Financeira	Despesas de Captação (b1) Despesas de Obrigações por Empréstimos e Repasses (b2) Despesas de Operações de Arrendamento Mercantil (b3) Resultado de Operações de Câmbio (b4) Resultado de Provisão para Créditos de Difícil Liquidação (b5) Despesas de Intermediação Financeira (b) = (b1) + (b2) + (b3) + (b4) + (b5)
Resultado de Intermediação Financeira (c) = (a) + (b)	
Outras Receitas/Despesas Operacionais	
	Rendas de Prestação de Serviços (d1) Rendas de Tarifas Bancárias (d2) Despesas de Pessoal (d3) Despesas Administrativas (d4) Despesas Tributárias (d5) Resultado de Participações (d6) Outras Receitas Operacionais (d7) Outras Despesas Operacionais (d8) Outras Receitas/Despesas Operacionais (d) = (d1) + (d2) + (d3) + (d4) + (d5) + (d6) + (d7) + (d8)
Resultado Operacional (e) = (c) + (d)	
Resultado Não Operacional (f)	
Resultado antes da Tributação, Lucro e Participação (g) = (e) + (f)	
Imposto de Renda e Contribuição Social (h)	
Participação nos Lucros (i)	
Lucro Líquido (j) = (g) + (h) + (i)	
Juros Sobre Capital Próprio (k)	

Nota: Elaboração própria com base na composição das colunas do DRE presente no if.data.

Tabela 6. Instituições Individuais – resumo

Ativo Total
Carteira de Crédito Classificada
Passivo Circulante e Exigível a Longo Prazo e Resultados de Exercícios Futuros
Captações
Patrimônio Líquido
Lucro Líquido
Número de Agências
Número de Postos de Atendimento

Nota: Elaboração própria com base na composição das colunas do Resumo presente no if.data.

Tabela 7. Balanço: Ativo

Disponibilidades (a)
Aplicações Interfinanceiras de Liquidez (b)
TVM e Instrumentos Financeiros Derivativos (c)
Operações de Crédito
Operações de Crédito (d1)
Provisão sobre Operações de Crédito (d2)
Operações de Crédito Líquidas de Provisão (d)
Arrendamento Mercantil
Arrendamento Mercantil a Receber (e1)
Imobilizado de Arrendamento (e2)
Credores por Antecipação de Valor Residual (e3)
Provisão sobre Arrendamento Mercantil (e4)
Arrendamento Mercantil Líquido de Provisão (e)
Outros Créditos - Líquido de Provisão (f)
Outros Ativos Realizáveis (g)
Permanente Ajustado (h)
Ativo Total Ajustado (i) = (a) + (b) + (c) + (d) + (e) + (f) + (g) + (h)
Credores por Antecipação de Valor Residual (j)
Ativo Total (k) = (i) - (j)

Nota: Elaboração própria com base na composição das colunas do Ativo presente no if.data.

Instituições com até 20 agências (116)

- BANCO NEON S.A.
- BANCO RIBEIRÃO PRETO S.A.
- BANCO CETELEM S.A.
- BANCO SEMEAR S.A.
- BANCO RABOBANK INTERNATIONAL BRASIL S.A.
- BANCO BNP PARIBAS BRASIL S.A.
- BANCO COOPERATIVO DO BRASIL S.A. - BANCOOB
- BANCO KEB HANA DO BRASIL S.A.
- BANCO CATERPILLAR S.A.
- BANCO MORGAN STANLEY S.A.
- BANCO TOYOTA DO BRASIL S.A.
- BANCO CNH INDUSTRIAL CAPITAL S.A.
- HIPERCARD BANCO MÚLTIPLO S.A.
- BANCO J. SAFRA S.A.
- BANCO ALFA S.A.
- BANCO PSA FINANCE BRASIL S.A.
- BANCO ABN AMRO S.A.
- BANCO HONDA S.A.
- BANCO BRADESCARD S.A.
- BANCO DE LAGE LANDEN BRASIL S.A.
- BANCO BRADESCO FINANCIAMENTOS S.A.
- BANCO MONEO S.A.
- BANCO KDB DO BRASIL S.A.
- BANCO TOPÁZIO S.A.
- BANCO CSF S.A.
- BANCO ORIGINAL DO AGRONEGÓCIO S.A.
- CONCÓRDIA BANCO S.A.
- BANCO YAMAHA MOTOR DO BRASIL S.A.
- BANCO AGIBANK S.A.
- BANCO DA CHINA BRASIL S.A.
- SCANIA BANCO S.A.
- BANCO RANDON S.A.
- BANCO PETRA S.A.
- PARANÁ BANCO S.A.
- BANCO BBM S.A.
- BANCO BOCOM BBM S.A.
- BANCO CAPITAL S.A.
- BANCO WOORI BANK DO BRASIL S.A.
- BANCO ITAUCARD S.A.
- BANCO ITAÚ BBA S.A.
- ICBC DO BRASIL BANCO MÚLTIPLO S.A.
- COMMERZBANK BRASIL S.A. - BANCO MÚLTIPLO
- BANCO KOMATSU DO BRASIL S.A.
- BB - BANCO DE INVESTIMENTO S.A.
- BANCO DIGIO S.A.
- BANCO ABC BRASIL S.A.
- BANCO BTG PACTUAL S.A.
- BANCO MODAL S.A.
- BANCO GUANABARA S.A.
- BANCO INDUSTRIAL DO BRASIL S.A.
- BANCO BVA S.A.
- BANCO DE LA NACION ARGENTINA
- BANCO RURAL S.A.
- BANCO J.P. MORGAN S.A.
- BANCO LOSANGO S.A. - BANCO MÚLTIPLO
- BANCO CACIQUE S.A.
- BANCO CAIXA GERAL - BRASIL S.A.
- BANCO RODOBENS S.A.
- BANCO PROSPER S.A.
- BANIF - BANCO INTERNACIONAL DO FUNCHAL (BRASIL), S.A.
- BANCO MÁXIMA S.A.
- BANCO CITICARD S.A.
- BANCO MERCANTIL DE INVESTIMENTOS S.A.
- BANCO PORTO REAL DE INVESTIMENTOS S.A.
- BNY MELLON BANCO S.A.
- BANCO MORADA S.A.
- DAYCOVAL LEASING - BANCO MÚLTIPLO S.A.
- PLURAL S.A. BANCO MÚLTIPLO
- BANCO ANDBANK (BRASIL) S.A.
- BANCO ITAÚ LEASING S.A.
- BCV - BANCO DE CRÉDITO E VAREJO S.A.
- BANCO DE LA REPUBLICA ORIENTAL DEL URUGUAY
- BANCO ARBI S.A.
- INTESA SANPAOLO BRASIL S.A. - BANCO MÚLTIPLO
- BANCO TRICURY S.A.
- BANCO VOLVO BRASIL S.A.
- BANCO INTERCAP S.A.
- BANCO FIBRA S.A.
- BANCO LUSO BRASILEIRO S.A.
- BANCO GMAC S.A.
- BANCO PAN S.A.
- BANCO BRADESCO CARTÕES S.A.
- BANCO VOTORANTIM S.A.
- BANCO BANKPAR S.A.
- BANCO MUFG BRASIL S.A.
- BANCO SUMITOMO MITSUI BRASILEIRO S.A.
- BANCO ALFA DE INVESTIMENTO S.A.
- BANCO MERCEDES-BENZ DO BRASIL S.A.
- OMNI BANCO S.A.
- BANCO SOFISA S.A.
- BANCO INDUSVAL S.A.
- BANCO BPN BRASIL S.A.
- BANCO CREFISA S.A.
- BANCO MIZUHO DO BRASIL S.A.
- BANCO BARCLAYS S.A.
- BANCO BMG S.A.
- BANCO ITAÚ VEÍCULOS S.A.
- BANCO FICSA S.A.
- BANCO SOCIETE GENERALE BRASIL S.A.
- BANCO PAULISTA S.A.
- BANK OF AMERICA MERRILL LYNCH BANCO MÚLTIPLO S.A.
- BANCO CRUZEIRO DO SUL S.A.
- BANCO PINE S.A.
- BANCO FIDIS S.A.
- BANCO RCI BRASIL S.A.
- DEUTSCHE BANK S.A. - BANCO ALEMÃO
- BANCO CIFRA S.A.
- BANCO RENDIMENTO S.A.
- BANCO CREDIBEL S.A.
- BANCO OLÉ BONSUCESSO CONSIGNADO S.A.
- NOVO BANCO CONTINENTAL S.A. - BANCO MÚLTIPLO
- BANCO CRÉDIT AGRICOLE BRASIL S.A.
- BANCO VR S.A.
- BANCO OURINVEST S.A.
- BANCO JOHN DEERE S.A.
- BANCO A.J. RENNER S.A.
- BANCO ORIGINAL S.A.

Instituições entre 20 e 2500 agências (16)

- BRB - BANCO DE BRASÍLIA S.A.
- BANCO INTER S.A.
- BANCO COOPERATIVO SICREDI S.A.
- KIRTON BANK S.A. - BANCO MÚLTIPLO
- BANCO DA AMAZÔNIA S.A.
- BANCO DO ESTADO DO PARÁ S.A.
- BANCO DO NORDESTE DO BRASIL S.A.
- CHINA CONSTRUCTION BANK (BRASIL) BANCO MÚLTIPLO S.A.
- BANCO DO ESTADO DE SERGIPE S.A.
- BANCO MERCANTIL DO BRASIL S.A.
- BANCO TRIÂNGULO S.A.
- BANESTES S.A. BANCO DO ESTADO DO ESPÍRITO SANTO

- BANCO CITIBANK S.A.
- BANCO SAFRA S.A.
- BANCO DAYCOVAL S.A.
- BANCO DO ESTADO DO RIO GRANDE DO SUL S.A.

Instituições com mais de 2500 agências (5)

- BANCO DO BRASIL S.A.
- CAIXA ECONOMICA FEDERAL
- ITAÚ UNIBANCO S.A.
- BANCO BRADESCO S.A.
- BANCO SANTANDER (BRASIL) S.A.

Tabela 8. Resultado teste de endogeneidade de Hausman (1978)

Variáveis de interesse	χ^2	p-valor	Modelo indicado
Ln(Renda crédito) * Pequenos	13.493	0.0959	Efeito Fixo
Ln(Renda crédito) * Médios	24.058	0.0020	Efeitos Aleatórios
Ln(Renda crédito) * Grandes	18.734	0.0163	Efeitos Aleatórios
Ln(Renda crédito) * Todos	17.095	0.0291	Efeitos Aleatórios
Ln(Renda serviço) * Pequenos	27.347	0.0006	Efeitos Aleatórios
Ln(Renda serviço) * Médios	24.482	0.0019	Efeitos Aleatórios
Ln(Renda serviço) * Grandes	15.157	0.0561	Efeitos Aleatórios
Ln(Renda serviço) * Todos	20.076	0.0100	Efeitos Aleatórios
Ln(Renda tarifas) * Pequenos	37.317	0.0000	Efeitos Aleatórios
Ln(Renda tarifas) * Médios	24.061	0.0022	Efeitos Aleatórios
Ln(Renda tarifas) * Grandes	28.217	0.0004	Efeitos Aleatórios
Ln(Renda tarifas) * Todos	32.254	0.0000	Efeitos Aleatórios
Ln(Despesas pessoal) * Pequenos	29.784	0.0002	Efeitos Aleatórios
Ln(Despesas pessoal) * Médios	36.839	0.0000	Efeitos Aleatórios
Ln(Despesas pessoal) * Grandes	24.788	0.0016	Efeitos Aleatórios
Ln(Despesas pessoal) * Todos	30.230	0.0001	Efeitos Aleatórios
Ln(Despesas adm.) * Pequenos	23.835	0.0024	Efeitos Aleatórios
Ln(Despesas adm.) * Médios	32.358	0.0000	Efeitos Aleatórios
Ln(Despesas adm.) * Grandes	27.199	0.0006	Efeitos Aleatórios
Ln(Despesas adm.) * Todos	28.623	0.0003	Efeitos Aleatórios
ROA * Pequenos	11.129	0.1945	Efeito Fixo
ROA * Médios	10.418	0.2369	Efeito Fixo
ROA * Grandes	8.9753	0.3444	Efeito Fixo
ROA * Todos	9.1073	0.3333	Efeito Fixo
ROE * Pequenos	9.0364	0.3392	Efeito Fixo
ROE * Médios	10.180	0.2526	Efeito Fixo
ROE * Grandes	7.2137	0.5138	Efeito Fixo
ROE * Todos	9.1529	0.3296	Efeito Fixo

Nota: Teste de Hausman (1978) com estimador de covariância robusto. Graus de liberdade em cada teste igual a 8. Níveis de significância representados por *p<0.1; **p<0.05; ***p<0.01.

Tabela 9. Resultados da variável Renda de operações de crédito pelo modelo de Efeitos Aleatórios

	<i>Variável de interesse:</i>			
	Ln(Renda crédito)			
	(1)	(2)	(3)	(4)
Ln(Prod. Industrial)	-11.849*** (1.084)	-11.846*** (1.083)	-11.850*** (1.088)	-11.847*** (1.081)
Ln(Câmbio)	1.225*** (0.324)	1.222*** (0.323)	1.217*** (0.324)	1.215*** (0.324)
Razão Compulsórios	1.307 (1.471)	1.308 (1.470)	1.286 (1.473)	1.276 (1.473)
IGP-M	-0.032 (0.032)	-0.032 (0.032)	-0.031 (0.032)	-0.031 (0.032)
CDI	-0.123*** (0.021)	-0.123*** (0.021)	-0.123*** (0.021)	-0.123*** (0.021)
Endividamento	-0.006 (0.024)	-0.006 (0.024)	-0.006 (0.024)	-0.006 (0.024)
HHI	0.811 (0.853)	0.818 (0.853)	0.819 (0.854)	0.815 (0.854)
Ln(Ativo)	0.976*** (0.038)	0.985*** (0.035)	0.991*** (0.038)	0.991*** (0.035)
Razão de liquidez	0.264 (1.309)	0.246 (1.309)	0.280 (1.313)	0.261 (1.314)
Alavancagem	-0.009* (0.005)	-0.009* (0.005)	-0.009* (0.005)	-0.009* (0.005)
Razão de depósitos	0.480** (0.211)	0.476** (0.211)	0.491** (0.211)	0.538** (0.212)
Razão de custos	0.004 (0.005)	0.004 (0.005)	0.004 (0.005)	0.004 (0.005)
Empréstimos/ativos	1.517 (0.932)	1.530 (0.932)	1.524 (0.936)	1.528 (0.930)
Constante	-2.917*** (1.040)	-3.546*** (0.957)	-3.566*** (0.982)	-2.362** (1.052)
Dummy P2P	0.077 (0.075)	0.219*** (0.069)	0.189*** (0.068)	1.073*** (0.179)
Pequenos	-0.512*** (0.192)	-	-	-
Médios	-	0.570*** (0.184)	-	-
Grandes	-	-	0.097 (0.311)	-
Todos	-	-	-	-1.261*** (0.431)
Dummy P2P*Pequenos	0.142*** (0.053)	-	-	-
Dummy P2P*Médios	-	-0.199*** (0.061)	-	-
Dummy P2P*Grandes	-	-	0.043 (0.060)	-
Dummy P2P*Todos	-	-	-	-0.890*** (0.168)
Observações	3,341	3,341	3,341	3,341
R ²	0.454	0.454	0.453	0.457
R ² ajustado	0.450	0.450	0.449	0.453
Estatística F	2,746.963***	2,750.570***	2,732.531***	2,772.395***

Nota: Modelo de efeitos aleatórios individuais e estimação dos componentes da variância pelo método de Swamy e Arora (1972), e variáveis *dummy* de ano (omitidas por razão de concisão). Número de observações em cada modelo igual a 3,341. Os desvios padrão estão entre parênteses. Níveis de significância representados por *p<0.1; **p<0.05; ***p<0.01.

Tabela 10. Resultados das variáveis de Renda e Despesas pelo modelo de Efeitos Aleatórios

	<i>Variáveis de interesse:</i>															
	Ln(Renda serviço)				Ln(Renda tarifas)				Ln(Despesas pessoal)				Ln(Despesas adm.)			
	(1)	(2)	(3)	(4)	(1)	(2)	(3)	(4)	(1)	(2)	(3)	(4)	(1)	(2)	(3)	(4)
Dummy Fintech	0.206***	-	-	-	0.137**	-	-	-	0.116***	-	-	-	0.086**	-	-	-
*Pequenos	(0.062)	-	-	-	(0.063)	-	-	-	(0.043)	-	-	-	(0.037)	-	-	-
Dummy Fintech	-	-0.192***	-	-	-	-0.176***	-	-	-	-0.076*	-	-	-	-0.024	-	-
*Médios	-	(0.063)	-	-	-	(0.068)	-	-	-	(0.046)	-	-	-	(0.039)	-	-
Dummy Fintech	-	-	-0.173**	-	-	-	0.005	-	-	-	-0.187***	-	-	-	-0.221***	-
*Grandes	-	-	(0.071)	-	-	-	(0.068)	-	-	-	(0.057)	-	-	-	(0.057)	-
Dummy Fintech	-	-	-	-2.614***	-	-	-	-2.151***	-	-	-	-3.728***	-	-	-	-3.357***
*Todos	-	-	-	(0.550)	-	-	-	(0.476)	-	-	-	(0.676)	-	-	-	(0.437)
Constante	-6.398***	-7.809***	-7.579***	-8.046***	-3.591**	-6.782***	-6.453***	-4.533**	2.895***	0.292	0.960	-0.638	0.714	-0.648	-0.378	-0.743
	(1.804)	(1.746)	(1.780)	(1.947)	(1.775)	(1.655)	(1.678)	(2.032)	(0.973)	(0.951)	(0.967)	(1.256)	(0.809)	(0.760)	(0.767)	(1.050)
Dummy Fintech	-0.280**	-0.088	-0.108	2.469***	0.010	0.143	0.116	2.243***	-0.124	-0.024	-0.023	3.653***	-0.106	-0.035	-0.027	3.284***
	(0.132)	(0.131)	(0.129)	(0.563)	(0.125)	(0.121)	(0.120)	(0.488)	(0.089)	(0.088)	(0.088)	(0.707)	(0.066)	(0.063)	(0.062)	(0.457)
Pequenos	-1.132***	-	-	-	-2.801***	-	-	-	-2.096***	-	-	-	-1.135***	-	-	-
	(0.238)	-	-	-	(0.380)	-	-	-	(0.153)	-	-	-	(0.169)	-	-	-
Médios	-	0.932***	-	-	-	2.499***	-	-	-	1.544***	-	-	-	0.773***	-	-
	-	(0.223)	-	-	-	(0.392)	-	-	-	(0.162)	-	-	-	(0.173)	-	-
Grandes	-	-	1.230***	-	-	-	2.664***	-	-	-	2.890***	-	-	-	1.740***	-
	-	-	(0.398)	-	-	-	(0.534)	-	-	-	(0.277)	-	-	-	(0.298)	-
Todos	-	-	-	-0.064	-	-	-	-2.549**	-	-	-	0.661	-	-	-	-0.234
	-	-	-	(0.890)	-	-	-	(1.163)	-	-	-	(0.924)	-	-	-	(0.799)
Observações	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341
R ²	0.240	0.238	0.235	0.245	0.208	0.205	0.202	0.210	0.436	0.401	0.393	0.425	0.467	0.459	0.462	0.506
R ² ajustado	0.234	0.233	0.229	0.239	0.203	0.199	0.196	0.204	0.431	0.396	0.388	0.421	0.462	0.455	0.458	0.502
Estatística F	1,047.459	1,037.252	1,019.139	1,076.774	872.414**	854.839**	838.569**	877.798**	2,559.058	2,217.712	2,142.798	2,449.404	2,898.857	2,810.776	2,840.729	3,390.459
	***	***	***	***	*	*	*	*	***	***	***	***	***	***	***	***

Nota: Modelo de efeitos aleatórios individuais e estimação dos componentes da variância pelo método de Swamy e Arora (1972), e variáveis *dummy* de ano e de controle macroeconômico e controle bancário omitidas por razão de concisão. Os desvios padrão estão entre parênteses. Níveis de significância representados por * $p < 0.1$; ** $p < 0.05$; *** $p < 0.01$.

Tabela 11. Resultados das variáveis de Desempenho pelo modelo de Efeitos Aleatórios

	<i>Variáveis de interesse:</i>							
	ROA				ROE			
	(1)	(2)	(3)	(4)	(1)	(2)	(3)	(4)
Dummy Fintech *Pequenos	0.0003 (0.001)	-	-	-	-0.008 (0.013)	-	-	-
Dummy Fintech *Médios	-	-0.0005 (0.001)	-	-	-	-0.002 (0.011)	-	-
Dummy Fintech *Grandes	-	-	0.0004 (0.001)	-	-	-	0.032* (0.018)	-
Dummy Fintech *Todos	-	-	-	0.021*** (0.004)	-	-	-	0.329 (0.250)
Ln(Prod. Industrial)	-0.077** (0.031)	-0.078** (0.031)	-0.077** (0.031)	-0.078** (0.031)	-0.615*** (0.235)	-0.617*** (0.235)	-0.615*** (0.235)	-0.621*** (0.239)
Ln(Câmbio)	0.024** (0.011)	0.024** (0.011)	0.024** (0.011)	0.024** (0.011)	0.195*** (0.074)	0.195*** (0.075)	0.194*** (0.074)	0.198*** (0.076)
Razão Compulsórios	0.026 (0.054)	0.027 (0.054)	0.027 (0.054)	0.028 (0.054)	0.340 (0.398)	0.344 (0.399)	0.340 (0.398)	0.355 (0.400)
IGP-M	-0.0002 (0.001)	-0.0002 (0.001)	-0.0002 (0.001)	-0.0002 (0.001)	-0.002 (0.009)	-0.002 (0.009)	-0.002 (0.009)	-0.002 (0.009)
CDI	-0.001 (0.001)	-0.001 (0.001)	-0.001 (0.001)	-0.001 (0.001)	-0.007 (0.006)	-0.007 (0.006)	-0.007 (0.006)	-0.007 (0.006)
Endividamento	-0.001 (0.001)	-0.001 (0.001)	-0.001 (0.001)	-0.001 (0.001)	0.0002 (0.006)	0.0002 (0.006)	0.0002 (0.006)	0.0001 (0.006)
HHI	0.028 (0.029)	0.028 (0.029)	0.028 (0.029)	0.028 (0.029)	-0.163 (0.247)	-0.163 (0.247)	-0.162 (0.247)	-0.162 (0.239)
Ln(Ativo)	0.004*** (0.001)	0.003*** (0.001)	0.004*** (0.001)	0.003*** (0.001)	0.043*** (0.008)	0.041*** (0.008)	0.044*** (0.008)	0.039*** (0.007)
Razão de liquidez	0.701*** (0.128)	0.700*** (0.128)	0.698*** (0.128)	0.697*** (0.128)	2.013*** (0.734)	1.995*** (0.733)	1.994*** (0.729)	1.974*** (0.715)
Alavancagem	-0.0001 (0.0002)	-0.0001 (0.0002)	-0.0001 (0.0002)	-0.00003 (0.0002)	-0.015*** (0.004)	-0.015*** (0.004)	-0.015*** (0.004)	-0.014*** (0.004)
Razão de depósitos	-0.006 (0.009)	-0.006 (0.009)	-0.006 (0.009)	-0.006 (0.009)	0.114** (0.043)	0.112** (0.043)	0.113*** (0.043)	0.106** (0.039)
Razão de custos	-0.00005 (0.00005)	-0.00005 (0.0001)	-0.00005 (0.0001)	-0.00005 (0.0001)	0.001** (0.0003)	0.001** (0.0003)	0.001** (0.0003)	0.001** (0.0003)
Empréstimos/ativos	-0.265*** (0.050)	-0.264*** (0.050)	-0.263*** (0.050)	-0.263*** (0.050)	-0.795*** (0.282)	-0.789*** (0.282)	-0.788*** (0.281)	-0.775*** (0.272)
Constante	-0.024 (0.035)	-0.010 (0.034)	-0.016 (0.034)	-0.001 (0.033)	-0.683** (0.268)	-0.631** (0.260)	-0.662** (0.262)	-0.628** (0.285)
Dummy Fintech	-0.001 (0.002)	-0.0002 (0.002)	-0.0004 (0.002)	-0.021*** (0.005)	0.004 (0.014)	-0.002 (0.013)	-0.004 (0.013)	-0.328 (0.251)
Pequenos	0.008*** (0.002)	-	-	-	0.031** (0.014)	-	-	-
Médios	-	-0.004*** (0.001)	-	-	-	-0.009 (0.011)	-	-
Grandes	-	-	-0.014*** (0.005)	-	-	-	-0.077*** (0.027)	-
Todos	-	-	-	-0.006 (0.004)	-	-	-	0.027 (0.078)
Observações	3,341	3,341	3,341	3,341	3,341	3,341	3,341	3,341
R ²	0.226	0.225	0.226	0.227	0.224	0.223	0.224	0.231
R ² ajustado	0.221	0.220	0.220	0.221	0.218	0.218	0.218	0.225
Estatística F	969.913***	964.165***	968.598***	971.471***	955.945***	953.827***	958.699***	993.343***

Nota: Modelo de efeitos aleatórios individuais e estimação dos componentes da variância pelo método de Swamy e Arora (1972), e variáveis *dummy* de ano (omitidas por razão de concisão). Os desvios padrão estão entre parênteses. Níveis de significância representados por *p<0.1; **p<0.05; ***p<0.01.