



FACULTAD
DE CIENCIAS
ECONÓMICAS



Fintechs e inclusión financiera en el mercado crediticio argentino

Illa, Julián Luciano

julianlucianoilla@mi.unc.edu.ar

Licenciatura en economía

Trabajo final de grado

Director: Dr. Ariel Alejandro Barraud



Fintechs e inclusión financiera en el mercado crediticio argentino por Julián Luciano Illa se distribuye bajo una [Licencia Creative Commons Atribución-CompartirIgual 4.0 Internacional](https://creativecommons.org/licenses/by-sa/4.0/).

Resumen

El trabajo realiza una revisión literaria sobre el estado del arte de los modelos de calificación crediticia utilizados por empresas fintech, y, al mismo tiempo, recaba información sobre la evidencia empírica de la aplicación de los mismos en el mercado crediticio global. Por otro lado, analiza el contexto del mercado crediticio argentino y evalúa la penetración actual de empresas fintech sobre el mismo y la potencial oportunidad de ampliar el acceso crediticio de la población a través de estas empresas. Algunos resultados importantes de la evidencia empírica son: 1) la información no tradicional y los modelos basados en *machine learning* mejoran la evaluación del riesgo crediticio (comparados con la industria tradicional), ampliando el crédito y ofreciendo menores tasas y 2) la aplicación de tales modelos puede tener consecuencias macroeconómicas. En Argentina, se verifica que segmentos que no tienen acceso a crédito en instituciones tradicionales (ya sea por edad, ingresos o ubicación geográfica), hacen un mayor uso del crédito fintech que aquellos que sí tienen acceso.

Índice

Introducción	1
Revisión de literatura	3
2.1 Determinantes del crédito fintech	5
Factores de demanda	6
Factores de oferta	7
2.2. Fortalezas de modelos de préstamos basados en Machine Learning	9
Los modelos de machine learning pueden evaluar el riesgo crediticio de pequeños prestatarios de manera económica.	9
Los modelos de machine learning pueden endurecer la información blanda	10
Los modelos de machine learning pueden capturar mejor relaciones no lineales entre variables	12
El aprendizaje automático podría mitigar la información asimétrica	12
2.3. Debilidades de modelos de préstamos basados en Machine Learning	13
Los modelos basados en machine learning enfrentan riesgos de exclusión financiera	13
Los modelos podrían causar problemas respecto de la protección del consumidor	14
El aprendizaje automático puede no detectar cambios estructurales	14
Evidencia empírica sobre el uso de modelos no tradicionales en el mercado crediticio	15
3.1 Evidencia en el uso de fuentes de datos alternativas	16
3.2 Evidencia en el uso de métodos innovadores en evaluaciones crediticias	20
3.3 Evidencia sobre la ampliación de acceso al crédito y el efecto de éste sobre el crecimiento	24
El mercado crediticio en Argentina	29
4.1 Penetración de billeteras virtuales	32
4.2 Tarjetas de crédito y líneas de microcrédito	34
4.3 Penetración crediticia según ubicación geográfica	40
Conclusiones	45
Referencias	48

1. Introducción

Uno de los mayores desafíos de las economías emergentes y de bajos ingresos es el alto costo del crédito. Este gran costo, sumado al racionamiento del crédito, aumentan la exclusión financiera, especialmente en pequeños prestatarios como pequeñas y medianas empresas (PyMEs) e individuos que tienen un importante rol en términos macroeconómicos.¹ Tal exclusión (o limitado acceso en algunas ocasiones) de los segmentos de menores ingresos de la población global con respecto al mercado crediticio genera un déficit de acceso a las finanzas altamente crítico.

Según The Global Findex Database 2017, el porcentaje promedio de adultos con un crédito en los doce meses anteriores a la fecha del estudio fue del 64% en economías avanzadas y 44% entre economías en desarrollo. Además, el 90% de los prestatarios en economías desarrolladas accedieron al crédito a través de una institución financiera o una tarjeta de crédito, mientras que en las economías en desarrollo, ‘familia y amigos’ fue la principal fuente declarada de acceso al crédito.

Un resultado importante de la teoría de las finanzas es que las instituciones financieras y los mercados juegan un papel crucial en la asignación eficiente de los recursos de capital en ausencia de información asimétrica, costos de transacción y otras imperfecciones de mercado². Sin embargo, cuando estas imperfecciones se presentan, la asignación óptima de recursos de capital puede verse comprometida; como se mencionó anteriormente, algunas empresas e individuos podrían verse excluidos de los mercados financieros, lo cual impactaría de manera negativa sobre la equidad del crecimiento económico.

La ampliación del acceso al crédito no es un fin en sí mismo, sino un medio para otros fines. En general, tener acceso a financiamiento permite a las firmas invertir y a los individuos suavizar el consumo y crear capital a lo largo del tiempo, aumentando la creación de negocios y

¹ Ver Sahay et al. (2015a)

² Mishkin, F. S. (2007)

ayudando a mejorar las condiciones de vida. También ayuda a firmas e individuos a protegerse contra shocks externos y a manejar mejor el riesgo financiero y económico de sus actividades.³

El uso de internet y otros avances digitales ayudaron a introducir una variedad de innovaciones en el sector financiero forzando a los mercados a repensar sus modelos de negocios. Los avances tecnológicos modernos han permitido la creación de nuevos modelos de negocios que emplean técnicas de análisis de datos modernas sobre grandes volúmenes de información (*Big data*⁴) y automatizan tareas para hacer más eficientes las decisiones crediticias. El uso de la tecnología ha posibilitado que el mercado del crédito Fintech⁵ ofrezca préstamos a una mayor velocidad y menor costo, garantizando préstamos a fracciones más grandes de la población, dando como resultado mayor inclusión financiera, mayor bienestar del consumidor y mayor estabilidad financiera.

La aparición de las compañías Fintech ofrece una oportunidad sin precedentes para atacar el problema de acceso a servicios financieros gracias a la penetración creciente de la tecnología móvil, cerrando la brecha entre el universo de no bancarizados, escasamente bancarizados y bancarizados⁶, abriendo la puerta a la economía digital global, a la vez que liderando un crecimiento económico más inclusivo.

El presente trabajo busca, por un lado, realizar una revisión literaria sobre el estado del arte de los modelos de calificación crediticia utilizados por empresas fintech, y, al mismo tiempo, recabar información sobre la evidencia empírica de la aplicación de los mismos en el mercado crediticio global. Por otro lado, se busca analizar el mercado crediticio argentino y evaluar la

³ Ver Sahay et al. (2015b)

⁴ Se conoce como *Big Data* a aquellas colecciones de datos grandes en volumen, y que, a su vez, crecen exponencialmente en el tiempo. Se trata de datos con un tamaño y una complejidad tan grandes que ninguna de las herramientas tradicionales de gestión de datos puede almacenarlos o procesarlos de manera eficiente.

⁵ Se refiere como *Fintech* al sector integrado por empresas que utilizan la tecnología para mejorar o automatizar los servicios y procesos financieros. Algunos autores se refieren como *BigTech* a aquellas empresas que proveen servicios financieros a través de tecnología pero que su unidad principal de negocio no son las finanzas, dejando el término *Fintech* sólo para aquellas empresas donde su actividad principal es la de conjugar servicios financieros y tecnología. En este trabajo se utilizará el término *Fintech* para referirse a ambos casos.

⁶ AFI (2018)

penetración actual de empresas fintech sobre el mismo y la potencial oportunidad de ampliar el acceso crediticio de la población a través de las mismas.

El trabajo se organiza de la siguiente manera. En la sección dos, se recorre el estado de la literatura respecto de: la importancia del acceso al crédito, la relación entre las Fintech y la inclusión financiera, los factores que proporcionan ventajas a las fintech en su evaluación crediticia y los factores y condiciones que propician el surgimiento de estas compañías en las diferentes economías. En la sección tres se revisan los principales hallazgos empíricos, particularmente respecto a la comparación de modelos de riesgo crediticio entre firmas Fintech y los bancos tradicionales. En la cuarta sección se realiza un análisis del acceso al crédito en Argentina y en la quinta, se concluye y se esbozan algunas recomendaciones de política económica.

2. Revisión de literatura

La teoría sugiere que las imperfecciones de mercado (como información asimétrica y costos de transacción) impiden que las personas en situación de pobreza escapen de ella debido al limitado acceso a servicios financieros formales. Por ejemplo, Galor & Zeira (1993) muestran que en presencia de imperfecciones en los mercados crediticios, los segmentos más vulnerables de la población no pueden pedir dinero prestado para invertir en su educación. Similarmente, en el modelo de Banerjee & Newman (1993), los mismos segmentos quedan imposibilitados de pedir dinero para comenzar su propio negocio. Estos modelos sugieren que un mayor acceso al crédito puede reducir la pobreza y la desigualdad, expandiendo el acceso a educación y a oportunidades de negocios.

En este sentido, varios estudios sugieren que mayores niveles de inclusión financiera se asocian con menores niveles de desigualdad del ingreso (Honohan 2007; Sahay et al. 2015b). Mookerjee & Kalipioni (2010) muestran que países con más sucursales bancarias per cápita

tienden a tener menos desigualdad de ingresos. Park & Mercado (2018) sugieren que aumentar la accesibilidad, disponibilidad y uso de servicios financieros reduce la brecha de ingresos entre ricos y pobres.

Cuando se analiza el impacto de las Fintech, la mayoría de los estudios encuentran que éstas son importantes impulsoras de la inclusión financiera (Jack & Suri 2011; Mbiti & Weil 2011; Ghosh 2016; Gosavi 2018). Hay evidencia de una fuerte relación entre los niveles de penetración de teléfonos celulares e inclusión financiera entre países (Andrinaiavo & Kpodar 2012; Ghosh 2016); y también, de una relación positiva entre el uso de dinero digital e inclusión financiera. Los individuos con una cuenta digital tienden a encontrarse más bancarizados, enviar y recibir remesas más frecuentemente y acumular más ahorros (Morawczynski 2009; Jack & Suri 2011; Mbiti & Weil 2011).

Que los individuos accedan a una cuenta digital no solo aumenta la inclusión financiera debido a que acceden a alternativas de pagos digitales, ahorro y control de ingresos y gastos, entre algunas características, sino que además visibiliza las transacciones de estos individuos que de otro modo ocurrirían con dinero en efectivo. Ello permite a las empresas conocer a sus clientes y poder ofrecer créditos no solo en base a sus patrones de consumo, sino también en base a su flujo de caja. Gosavi (2018) muestra que el dinero digital tiene impacto positivo en la inclusión financiera de pequeñas y medianas empresas a través del incremento en el acceso al crédito.

Dos grandes ventajas de las compañías Fintech a la hora de evaluar el riesgo crediticio de un aplicante son, por un lado, modelos de calificación crediticia basados en aprendizaje automático (*machine learning*)⁷, y por otro, acceso a grandes volúmenes de información alternativa respecto a los bureaus de crédito. Los modelos utilizados pueden incorporar información alternativa y capturar mejor las relaciones no lineales entre variables, pudiendo así

⁷ Refiere al uso y desarrollo de modelos computacionales que pueden aprender patrones y adaptarse a un conjunto de datos sin seguir instrucciones explícitas, mediante el uso de algoritmos y modelos estadísticos.

evaluar la probabilidad de no pago de un prestatario con escaso o nulo historial crediticio, quitándole importancia además a la necesidad de los aplicantes de contar con colaterales.⁸

Respecto a la información alternativa, la misma puede provenir de transacciones de servicios que la compañía ofrece, tanto financieros como de otra unidad de negocio, lo cual les permite a las compañías conocer a sus aplicantes en detalle casi sin costo alguno. Además, otra fuente de información alternativa que mejora los modelos crediticios puede provenir de la información digital extraída del teléfono móvil de un usuario, como por ejemplo el uso de redes sociales, el tipo de aplicaciones que tiene instaladas o la frecuencia con la cual realiza llamadas telefónicas.

Agarwal et al (2020) categoriza tal información en tres grupos: 1. huella social, que refiere a la presencia de aplicaciones de redes sociales, la red social de más uso, cantidad de contactos y llamadas entre otros datos, 2. huella social profunda, que captura información sobre los patrones de llamadas y 3. huella móvil extendida, que se refiere a la cantidad y tipo de aplicaciones instaladas en el celular, además del sistema operativo. Los autores contrastan modelos con información tradicional y alternativa para una muestra en India y encuentran que las tres categorías de información alternativa tienen significativamente mayor poder predictivo que la información tradicional utilizada por bancos.

2.1 Determinantes del crédito fintech

En los últimos años, se ha observado un creciente interés por parte de investigadores por los factores que permitieron que el crédito Fintech haya crecido más en algunas jurisdicciones que en otras. Estos pueden dividirse en factores de demanda y de oferta.

⁸ Ver Gambacorta, L. et al. (2020)

Factores de demanda

Bajos niveles de inclusión financiera en países emergentes crean una fuente de demanda previamente desatendida. Según el Banco Mundial, 1,7 mil millones de personas alrededor del mundo se encuentran no bancarizadas, de las cuales aproximadamente la mitad pertenece a economías en desarrollo.⁹ El alto costo de establecer sucursales bancarias en zonas con baja densidad poblacional reduce el acceso de los consumidores a servicios financieros, lo cual puede ser causa y a la vez consecuencia de la falta de documentación y/o historial crediticio de los potenciales clientes, creando un círculo vicioso de exclusión financiera difícil de revertir.¹⁰

Donde empresas y consumidores se encuentren con una demanda de servicios financieros desatendida, evidenciado por una baja proporción de la población con cuenta bancaria o tarjetas de crédito, es donde se encuentra una oportunidad para el crecimiento del crédito Fintech. Hau et al. (2018) y Huang et al. (2018) encuentran que el crédito Fintech logra atender la demanda insatisfecha en China, y similares resultados se encuentran para Alemania en De Roure et al. (2016) y para Estados Unidos en Tang (2019) y Jagtiani & Lemieux (2018). Un ejemplo para países en desarrollo es el de Argentina: “Una encuesta realizada en 2016 por Mercado Libre encontró que el 70% de los vendedores de su plataforma estaban interesados en tomar un préstamo para invertir en su negocio, pero solo el 25% de ellos tenía acceso a préstamos bancarios” (Frost et al., 2019).

Otro factor de incumbencia son las preferencias de los consumidores, ya que los individuos y las pequeñas empresas más afines a las nuevas tecnologías serán más propensos a utilizar la oferta financiera de las Fintech. Los segmentos jóvenes podrían mostrar mayor interés por los servicios financieros digitales por razones de conveniencia, velocidad y personalización. Además, algunas empresas Fintech gozan de reconocimiento de marca y credibilidad. Una

⁹ Ver Demirguc-Kunt et al. (2018)

¹⁰ Bain & Company (2017) encuentra que la mayor demanda de productos financieros provistos por empresas tecnológicas se concentra en países donde la experiencia en sucursales bancarias consume más tiempo y es más incómoda, tales como India y México, donde el 91% y 81% respectivamente prefieren manejar sus finanzas a través de empresas tecnológicas.

encuesta realizada por Bain & Company (2017) indica que el 73% de los estadounidenses de entre 18 y 34 años utilizaría productos financieros de empresas tecnológicas, mientras que la adopción sería del 61% para adultos de entre 35-54 años y solo del 42% en mayores de 55 años. A su vez, la misma encuesta revela que Amazon y PayPal serían las empresas tecnológicas con mayor confianza por parte del público estadounidense con respecto a la provisión de servicios financieros, casi al nivel de los bancos.¹¹

Factores de oferta

El grado de fortaleza de la protección legal hacia prestamistas y prestatarios, junto con la habilidad de las autoridades públicas para hacer cumplir la ley, determina el desarrollo de los mercados de crédito tradicional (Porta et al., 1998), por lo cual, varios estudios sugieren que ello también podría jugar un papel importante en el crecimiento del crédito Fintech. El desarrollo de un sistema legal, representado por medidas como la calidad de ejecución de los contratos y la protección de los derechos de propiedad y de los derechos de los prestatarios a través de leyes de quiebras, se presenta como altamente significativo en Rau (2020) y Haddad (2019).

En consonancia con lo anterior, las regulaciones en algunos países emergentes crean entornos más favorables en los cuales las Fintech pueden ofrecer servicios financieros. Algunos gobiernos han introducido proactivamente servicios financieros como el dinero digital dentro de sus esquemas regulatorios, permitiendo a empresas tecnológicas ofrecer servicios que antes les eran prohibidos por regulación.¹²

Algunos gobiernos han desarrollado sistemas de pagos más ágiles, como UPI en India, PIX en Brasil, SPEI en México, FAST en Turquía y FPS en Rusia, entre otros. Además, las iniciativas de *open-banking* también contribuyen a una mayor competencia en los servicios financieros, permitiendo que usuarios compartan sus datos entre diferentes entidades a través de

¹¹ Ver Du Toit et al. (2017).

¹² Ver International Monetary Fund (2018).

APIs (*application programming interfaces*) seguras, lo cual permite que las firmas accedan a una información a la que anteriormente no podían, logrando así mejorar sus modelos de evaluación de riesgo crediticio. Desde 2018 hasta la fecha, China, India, México y Brasil son los países emergentes que mayores avances han hecho en llevar adelante una estrategia de *open-banking*.

También puede ocurrir que las regulaciones financieras existentes, como por ejemplo reglas de protección al consumidor o requerimientos prudenciales para entidades financieras, no apliquen igualmente a firmas Fintech que al sector bancario tradicional. Ello podría resultar en menores costos y una ventaja competitiva para tales firmas; aunque podría llevar a conformar una cartera de clientes más riesgosa.

Las empresas Fintech tienen acceso a una gran cantidad y variedad de datos de sus clientes, lo cual les proporciona información superior para evaluar la solvencia de sus prestatarios y asegurados, traducándose o bien en evaluaciones más precisas a la hora de otorgar créditos y seguros, o bien en menores costos de intermediación. Jagtiani & Lemieux (2019) y Fuster et al. (2019) encuentran que tales ventajas son significativas para empresas Fintech.

Otro factor importante que posibilita el crecimiento de las firmas Fintech es su ventaja tecnológica. Debido al uso extensivo que hacen de nuevas tecnologías, como *machine learning* y *deep learning*¹³, las empresas Fintech pueden procesar más hábilmente los datos que el sector financiero tradicional, por ejemplo, a través de mejor tecnología de detección. Esto se refleja en menores tasas de impago o en menores costos (tasa cobrada a clientes) por préstamos y/o seguros otorgados.

Por último, el grado de competencia en el sector bancario juega un papel importante. Bancos y otras instituciones financieras podrían encontrarse blindados frente a la competencia

¹³ *Deep learning* es en realidad un subcampo de *machine learning* y se compone básicamente de modelos de redes neuronales; la forma en que ambas difieren es cómo aprende cada algoritmo. *Deep learning* automatiza gran parte de la extracción de características de los datos, lo cual elimina parte de la intervención humana manual requerida y permite el uso de conjuntos de datos más grandes. Puede entenderse como una forma de escalar *machine learning* donde es menos necesaria la intervención humana para que el modelo aprenda de los datos.

gracias a la regulación o al poder de mercado en el sector. La mayoría de los estudios aproximan el grado de competencia en el sector bancario, encontrando que los préstamos se encuentran más desarrollados mientras menos competitivo es el sector, ya que ello se traduce generalmente en mayores costos unitarios a priori, lo cual hace más atractiva la entrada de nuevos competidores, incluidas las firmas Fintech.

2.2. Fortalezas de modelos de préstamos basados en *Machine Learning*

Los modelos de *machine learning* pueden evaluar el riesgo crediticio de pequeños prestatarios de manera económica.

Los bancos por lo general se abstienen de evaluar el riesgo crediticio de pequeños prestatarios ya que el pequeño monto del préstamo junto con su alto riesgo potencial no justifican el costo de emplear un experto para que examine cada caso y escriba las condiciones del préstamo. Según World Economic Forum (2016), el costo hundido de iniciar una evaluación crediticia es el mayor determinante de exclusión financiera en muchos individuos y PyMEs.

Sin embargo, la automatización de la evaluación crediticia le permite a las Fintech evaluar la solvencia de PyMEs y pequeños prestatarios con mucha mayor frecuencia que la industria tradicional. Al automatizar el proceso de evaluación, las compañías Fintech pueden calcular mejor la solvencia de prestatarios haciendo pequeños desembolsos crediticios a una frecuencia mucho más alta y monitoreando el repago en tiempo real. De esa manera, las empresas Fintech pueden elegir con mayor precisión a los prestatarios que van a recibir crédito en vez de racionarlo entre quienes tienen historial crediticio suficiente, mejorando así las asimetrías de información existentes en el mercado.

Además, las compañías Fintech tienen ventajas de información, ya que acceden a información transaccional de sus usuarios. Esta información puede provenir de pagos de servicios y/o telecomunicaciones, pagos en tiendas físicas (a través de QR por ejemplo),

transferencias de dinero y pagos con tarjetas, entre otras. También puede provenir de transacciones referidas a una unidad de negocio no financiera de la empresa, como pueden ser pagos y cobros en una plataforma de comercio electrónico. Las compañías Fintech que ofrecen créditos y que nacieron como un *e-commerce* (caso de Amazon, Mercado Libre y Alibaba por ejemplo) pueden observar las tendencias de ventas y los flujos de caja de los vendedores activos de sus plataformas, reduciendo extremadamente el costo de acceder a tal información. Además, ello les permite otorgar préstamos basados en los flujos de caja sin requerir colateral alguno, el cual representa un gran obstáculo para pequeñas compañías y prestatarios que intentan acceder a créditos a través de bancos.¹⁴

Compañías Fintech que nacieron con una unidad de negocio no financiera y luego comenzaron a ofrecer servicios financieros, pueden complementar la información transaccional de su negocio principal con la de su unidad financiera para proveer financiamiento no solo a vendedores sino también a consumidores que serían incapaces de obtener un préstamo personal a través del sistema bancario tradicional, mejorando así la inclusión financiera.

Los modelos de *machine learning* pueden endurecer la información blanda

Se conoce que los modelos de *machine learning* (*ML*) se desempeñan particularmente bien en presencia de información dura. De acuerdo a Liberti & Petersen (2019), la información dura se caracteriza por dos propiedades: 1) tiene un valor numérico para los datos que mide la variable de manera cardinal y 2) es independiente del proceso de recolección de datos. Variables como ingreso, deuda, número de empleados, y ventas son algunos ejemplos de información dura que podrían usarse para estimar la probabilidad de repago de deuda de un prestatario.

Un gran desafío al evaluar los valores de los activos de pequeños prestatarios es que no hay un mercado lo suficientemente líquido para descubrir el precio de los mismos. En tales casos, la práctica común es aplicar modelos de *pricing* específicos para el activo, los cuales

¹⁴ Ver Frost et al. (2019)

dependen en gran medida del juicio del evaluador. Sin embargo, el desafío al procesar información blanda a través de modelos de *machine learning* es un problema de limitación de datos. Una vez que se tiene suficiente volumen de datos sin tanto “ruido”, los modelos de clasificación de *ML* pueden convertir la información blanda en dura, que van desde actividad en redes sociales hasta la locación física de las actividades de quienes aplican al préstamo. Los modelos de *ML* ofrecen la posibilidad de pre-procesar e incorporar datos no estructurados en el análisis, lo cual facilita el endurecimiento de la información blanda obtenida de una gran variedad de fuentes.

Como resultado, los modelos de *ML* pueden mejorar el *pricing* de los activos suscritos como colateral por parte de los prestatarios, encontrando patrones comunes a través de información no tradicional. Algunas aplicaciones pueden encontrarse en Jagtiani & Lemieux (2017), donde se muestra que el uso de datos no tradicionales mejoran la evaluación crediticia por parte de las firmas Fintech en Estados Unidos al compararse contra la evaluación que se hace mediante el sistema FICO¹⁵. Del mismo modo, Berg et al. (2020) muestra que información de fácil acceso acerca de la huella digital¹⁶ de los aplicantes mejora la performance de los modelos crediticios al compararse contra los modelos tradicionales.

Los modelos de *machine learning* pueden capturar mejor relaciones no lineales entre variables

En tanto la información extra recolectada y usada por los modelos de aprendizaje automático sea informativa acerca de los prestatarios, los modelos basados en *ML* pueden desempeñarse mejor que los tradicionales al capturar mayores dimensiones de no linealidad. Por

¹⁵ Fair Isaac Company (FICO) es una compañía de análisis de datos focalizada en brindar servicios de *scoring* crediticio, siendo sus evaluaciones usadas por el 90% de las instituciones prestamistas más importantes de Estados Unidos.

¹⁶ Refiere al conjunto de información que existe en internet sobre las actividades *online* de una persona. Ejemplos pueden ser registros de compras en internet, registro de sitios por los cuales navega, actividad en redes sociales y foros, entre otros.

ejemplo, a través de una partición efectiva de las características de los prestatarios, estos modelos pueden encontrar indicadores crediticios para aquellos con nulo historial crediticio. De este modo, el aprendizaje automático es capaz de evaluar mejor a los prestatarios, y evitar que el segmento de alta calidad domine la muestra e incline los resultados a su favor si el modelo no distingue entre diferentes segmentos de prestatarios (por ejemplo, regresiones logísticas). Por lo tanto, mientras que a los prestatarios con un pobre o nulo historial crediticio (según modelos tradicionales) les sería negado un crédito, las compañías Fintech podrían otorgárselo.

El aprendizaje automático podría mitigar la información asimétrica

Otra complicación que aparece en el mercado crediticio es la asimetría de información entre prestamista y prestatario, lo cual ha creado una extensa literatura en finanzas corporativas. Los problemas de selección adversa y riesgo moral podrían aparecer cuando el prestamista no pueda obtener información fiable acerca del prestatario, a la vez que este último tenga un incentivo a reportar información adulterada para obtener mejores términos sobre el crédito. Ello resultaría en racionamiento del crédito por parte del prestamista al tratar de evitar pérdidas; y, según Tirole (2010), el grado de racionamiento se volvería extremo a medida que la asimetría de información se intensificase.

Los modelos basados en *ML* podrían mitigar parte del racionamiento al identificar indicadores de riesgo crediticio a través de mayor volumen de datos e identificando diferencias entre prestatarios a través de modelos de clasificación. Esto podría lograrse detectando relaciones no lineales entre variables que no podrían lograrse con enfoques tradicionales. Además, la tecnología moderna permite un mejor control sobre prestatarios, examinando su comportamiento más frecuentemente, incluso en tiempo real. Por ejemplo, textos, imágenes y videos pueden ser recolectados y procesados para evaluar el cumplimiento del crédito. Tal monitoreo podría mitigar problemas de riesgo moral.

Sin embargo, mientras los modelos basados en *ML* obtienen una mejor evaluación del riesgo crediticio de los prestatarios, podrían tener un impacto heterogéneo, resultando en la exclusión de una sección de aplicantes, dado que el prestamista puede tomar decisiones mejor informadas. Tal exclusión es, sin embargo, consistente con los principios prudenciales y la gestión segura del riesgo y podría resultar en una mayor estabilidad financiera.

2.3. Debilidades de modelos de préstamos basados en *Machine Learning*

Los modelos basados en *machine learning* enfrentan riesgos de exclusión financiera

Los modelos se entrenan usando información disponible que no necesariamente es representativa de todas las clases de prestatarios. Como resultado, la falta de suficiente información relevante podría resultar en el rechazo de aplicantes que pertenezcan a ciertos grupos. Si una muestra es usada para hacer predicciones sobre la probabilidad de impago de prestatarios sin acceso al mercado crediticio, los resultados van a estar contaminados por el efecto de la exclusión financiera tradicional de esos prestatarios y el modelo continuará asignando un bajo puntaje crediticio. En tales casos, características como género, raza y religión que podrían causar ciertos sesgos deberían ser excluidas del modelo. Aunque tales variables podrían, sin embargo, ser usadas para evaluar la existencia de sesgos del modelo de clasificación y evitar la discriminación.¹⁷

Los modelos podrían causar problemas respecto de la protección del consumidor

El uso de información recolectada a través grandes bases de datos (incluidas las redes sociales e internet de las cosas¹⁸) no solo presenta problemas sobre la relevancia de la misma, sino también sobre la protección de los consumidores, ya que la exclusión podría provenir de

¹⁷ Ver Berendt & Preibusch (2014).

¹⁸ La Internet de las cosas (IoT en inglés) describe la red de objetos físicos ("cosas") que llevan incorporados sensores, software y otras tecnologías con el fin de conectarse e intercambiar datos con otros dispositivos y sistemas a través de Internet. Estos dispositivos van desde objetos domésticos comunes (como un lavarropas o aire acondicionado) hasta herramientas industriales sofisticadas.

usar datos personales en base a decisiones tomadas por modelos matemáticos difíciles de explicar. Además, debido a cómo funcionan los modelos¹⁹, puede ser difícil de detectar y probar la dominancia de algún factor en el resultado final de la clasificación crediticia, lo cual deja lugar para decisiones poco éticas e impide la supervisión.

Una forma de mitigar este problema es asegurarse de que el conjunto de variables no incluya características que podrían ser discriminatorias. Además, los modelos podrían listar las variables que más contribuyen utilizando la técnica de *feature importance*²⁰. Los prestamistas podrían monitorear activamente los factores más importantes para la evaluación crediticia y evaluar si tienen sentido de negocio.

El aprendizaje automático puede no detectar cambios estructurales

Un desafío similar aparece cuando algún gran cambio repentino vuelve a la información histórica irrelevante para evaluar a nuevos clientes, es decir, el análisis de la muestra histórica no se generaliza para nuevos aplicantes por la significancia del cambio estructural (por ejemplo: una política macroeconómica o un cambio industrial). Si los encargados de construir el modelo de evaluación crediticia fallan en identificar tal cambio, el modelo entrenado podría acarrear costosos problemas.

Una desventaja de los modelos basados en *ML* es que el algoritmo subyacente no puede ser fácilmente modificado para reflejar información tácita como el conocimiento de negocio, la intuición y la anticipación de eventos no reflejados en la información disponible.

Además, indicadores falsos provistos por los prestatarios podrían dañar los modelos.

¹⁹ Para un mayor detalle ver Bazarbash (2019).

²⁰ Para un mayor detalle ver Bazarbash (2019).

3. Evidencia empírica sobre el uso de modelos no tradicionales en el mercado crediticio

Con el desarrollo del comercio electrónico y las redes sociales, la cantidad de datos que pueden usarse para analizar el riesgo crediticio se ha incrementado considerablemente, y los avances tecnológicos han disminuido el costo de almacenar y procesar tal información.

A la hora de evaluar el riesgo crediticio de potenciales clientes, el sector bancario tradicional utiliza mayormente fuentes de datos estandarizadas, tales como registros crediticios públicos y bureaus de crédito. Sin embargo, las compañías Fintech han sabido aprovechar la Inteligencia Artificial y el *Big Data* para complementar las fuentes de información estándar con nuevos datos no tradicionales, como por ejemplo la actividad telefónica (patrón de llamadas y mensajes y cantidad y tipo de aplicaciones instaladas), actividad en redes sociales y actividad en plataformas de comercio electrónico, entre otras fuentes. Ello permite construir perfiles crediticios más completos, incluso con información diaria, incrementando así la frecuencia de su monitoreo y permitiendo una evaluación crediticia en tiempo real.

En esta sección se revisa la evidencia empírica del impacto de las tecnologías digitales sobre el proceso por el cual se toman las decisiones de préstamos. De la evidencia empírica emergen los siguientes resultados principales: 1) la información *online* mejora la evaluación de los prestatarios, especialmente de aquellos con un registro crediticio pobre, 2) los modelos basados en nuevas técnicas (principalmente *machine learning*) se desempeñan mejor que los modelos tradicionales al predecir la probabilidad de impago de los prestatarios, 3) estos mismos modelos consiguen mejores predicciones ex-post ante shocks exógenos, 4) los modelos basados en técnicas de aprendizaje automático reducen sesgos raciales y etarios en el mercado crediticio, 5) tanto la información alternativa como las nuevas técnicas de modelado permiten o un mayor acceso al crédito o un menor precio para prestatarios con un riesgo calculado impreciso, 6) la ampliación del crédito a pequeñas y medianas empresas previamente excluidas del mercado crediticio podría tener efectos impulsores sobre el crecimiento de las mismas y 7) el crédito

fintech es menos dependiente del ciclo financiero comparado con el crédito bancario, lo cual puede tener efectos relevantes para la estabilidad del financiamiento a PyMEs y para los efectos de transmisión de la política monetaria.

3.1 Evidencia en el uso de fuentes de datos alternativas

El uso de información *online* como soporte para las decisiones crediticias ha atraído considerable interés académico en los últimos años. Berg et al. (2020) analiza el uso de huellas digitales para calibrar la solvencia de potenciales clientes. Usando una fuente de datos de 270.000 compras de una compañía alemana de comercio electrónico, los autores comparan el poder predictivo de las variables relacionadas a la huella digital contra las puntuaciones crediticias tradicionales de los bureaus. El trabajo encuentra que los modelos de evaluación de riesgo crediticio que usan solo variables referidas a la huella digital igualan, y en algunos casos superan, la *performance* de aquellos que utilizan únicamente información provista por los bureaus de crédito. Una de las principales implicancias del resultado es que, cuando la información de los bureaus no esté disponible, como por ejemplo para prestatarios con pobre o nulo historial crediticio, la huella digital puede ayudar a prestamistas a mitigar los problemas de información asimétrica, aliviando así las restricciones para prestatarios tradicionalmente excluidos.

Los modelos que combinan información proveniente de fuentes digitales con información tradicional muestran un poder de segmentación de clientes mayor que los modelos tradicionales. En tal sentido, la literatura documenta que el uso de información transaccional en los modelos de clasificación crediticia mejora el poder predictivo de los modelos.

Muchas pequeñas y medianas empresas en países emergentes no cumplen con los requisitos mínimos para solicitar un crédito, especialmente dado que no cuentan con reportes financieros auditados ni demás documentación formal. Las compañías Fintech son capaces de

superar tal limitación utilizando información alternativa, algunas veces proveniente de sus unidades de negocios, como en el caso de los *e-commerce*. Frost et al. (2019) utilizan información recogida por Ant Financial y Mercado Libre proveniente de: 1) transacciones (volúmenes de venta y precios promedio de venta), 2) reputación (tasa de devolución, tiempo en preparar el paquete y quejas) y 3) características específicas de la industria (estacionalidad de las ventas, tendencias y sensibilidad macroeconómica).

El trabajo compara el poder predictivo de los modelos de clasificación desarrollados por Mercado Libre para pequeñas y medianas empresas²¹ con las de los bureaus de crédito locales. Los autores encuentran que el puntaje interno de la compañía permite clasificar correctamente como prestatarios de bajo riesgo a aplicantes rotulados como prestatarios de medio y alto riesgo por el bureau local de crédito (lo que se conoce en la literatura como *undetected prime*). Si el proceso de decisión de asignación del crédito se basara únicamente en la información del bureau de crédito local, 30% de la audiencia objetivo de Mercado Crédito en Argentina sería calificada como de alto riesgo, y por tanto, excluida del programa de crédito.

Gambacorta et al. (2019) sugiere que los modelos que combinan información tradicional con información no tradicional obtenida de pagos con la tarjeta de crédito, aplicaciones digitales y plataformas de *e-commerce*, clasifican mejor a los prestatarios que los modelos que sólo utilizan información tradicional. Además, al estar el crédito de firmas Fintech más relacionado a características de la empresa aplicante (como volumen transaccionado) en vez de a las condiciones de la actividad económica local, el uso de grandes cantidades de información no tradicional podría reemplazar el rol que tiene el colateral en resolver problemas de información asimétrica. Ello tendría implicancias significativas para la macroeconomía y la conducción de la política monetaria.

²¹ El modelo de clasificación de Mercado Libre usa más de mil variables basadas en volúmenes de venta, precio de venta promedio y reputación del vendedor (por ejemplo, número de quejas).

El trabajo de Agarwal et al. (2020) sostiene la hipótesis de que muchos individuos serían “buenos prestatarios” si su solvencia pudiera ser evaluada usando información alternativa. Mientras que millones de personas alrededor del mundo nunca obtuvieron un crédito, muchos de ellos son usuarios activos de celulares que realizan compras online y tienen importante presencia en redes sociales. Los autores esgrimen que tales rastros de información no estructurada que los individuos dejan en internet podrían ser usados para predecir su comportamiento crediticio.

El trabajo utiliza la población de aplicantes a un crédito en una de las compañías Fintech más grandes de India para el período de 2016-2018. El prestatario no solo tiene información tradicional (*CIBIL score*, nivel de educación y ocupación), sino que además, recolecta información proveniente del teléfono celular del individuo como: aplicaciones instaladas, número de llamadas, número de contactos, número de conexiones sociales, sistema operativo del celular, entre otros tipos de información.

Los autores encuentran que mientras mayor es la huella digital, mayor es la probabilidad de aprobar el crédito solicitado. El número de contactos, de aplicaciones instaladas, de llamadas hechas y recibidas y la presencia de aplicaciones financieras se asocian positivamente con la aprobación del crédito. Los resultados incluso se mantienen al controlar por las puntuaciones de los bureaus, los ingresos, la edad, el nivel de educación y la ubicación de los aplicantes, descartando así posibles problemas de endogeneidad. Por tanto, las variables referidas a la huella digital proveen información incremental que sirve para predecir mejor el desempeño de un prestatario que solo utilizando información tradicional.

Además, el valor marginal de la información no tradicional aumenta en contextos donde las puntuaciones crediticias tradicionales tienen bajo poder discriminatorio. Por tanto, las compañías Fintech que utilizan información alternativa para clasificar a sus prestatarios podrían cobrar gran relevancia a la hora de expandir el acceso al crédito en países donde la información es pobre y la inclusión financiera baja.

Jagtiani & Lemieux (2019) comparan los préstamos originados por intermediarios tradicionales cara a cara con los otorgados por prestamistas Fintech. Los autores encuentran que el crédito provisto por operadores Fintech es más barato que créditos comparables otorgados a través de canales tradicionales, y que además, el precio se corresponde muy precisamente con la tasa de impago esperada. El trabajo muestra además, que la adopción de información no estándar para evaluar peticiones crediticias benefició a grupos de prestatarios previamente desatendidos.

3.2 Evidencia en el uso de métodos innovadores en evaluaciones crediticias

La combinación de información estándar y alternativa a menudo crea grandes cantidades de datos que son difíciles de analizar con los modelos de clasificación crediticia tradicionales como regresiones lineales o logit. Por eso, una parte de la literatura comenzó a investigar los beneficios de aplicar inteligencia artificial y aprendizaje automático. Estos métodos pueden manejar *sets* de datos con miles de variables para cada prestatario de manera no parametrizada, teniendo en cuenta funciones complejas y no lineales para relacionar las variables. Así, estos modelos tienden a proveer mejores predicciones fuera de la muestra que los modelos tradicionales, pero a menudo la relación entre la variable dependiente y las explicativas es difícil de interpretar (problema de la caja negra).²²

Los modelos basados en *machine learning* tienden a desempeñarse mejor que los modelos crediticios tradicionales cuando se conocen pocas características acerca del prestatario, gracias a su habilidad para extraer información de forma no lineal entre las variables. El trabajo de Moscatelli et al. (2020) muestra que estos modelos tienen un mejor desempeño prediciendo el resultado fuera de la muestra cuando los modelos son estimados usando únicamente información pública.

El trabajo de Gambacorta et al. (2019) compara el poder predictivo de los modelos de clasificación crediticia basados en *machine learning* contra los modelos tradicionales usando

²² Para un mayor detalle ver Bazarbash (2019).

información a nivel transaccional de una compañía Fintech china. Los autores intentan responder cuatro interrogantes: 1) ¿son los modelos de clasificación crediticia basados en *ML* mejores para predecir *defaults* que los modelos tradicionales? 2) ¿la información proveniente de fuentes no tradicionales mejora el poder predictivo de los modelos? 3) ¿cómo se desempeñan los diferentes modelos ante un shock exógeno? y 4) ¿cómo se desempeñan los diferentes modelos para clientes con diferentes historiales crediticios?

Para evaluar la significatividad de la información alternativa y de los modelos de *machine learning* los autores consideran tres modelos con *sets* de información diferentes. El modelo 1 usa sólo información de la calificación crediticia otorgada por la firma Fintech como variable independiente, el modelo 2 utiliza únicamente información tradicional como variables independientes, y el modelo 3 incluye tanto información tradicional como no tradicional como variables independientes. En los modelos 2 y 3 se utilizan las mismas variables explicativas que se usan en el modelo de *machine learning* utilizado para calcular la calificación crediticia de la propia compañía (13 variables tradicionales y 7 no tradicionales).

Si se utiliza tanto un modelo de regresión Tobit como uno Logit con la tasa de pérdida como variable dependiente, el modelo 1 exhibe el mayor R^2 , seguido del modelo 3 y por último el modelo 2. Al utilizar las curvas ROC para evaluar la precisión de las predicciones de los modelos, los resultados arrojan nuevamente que el modelo 1 predice con mayor cantidad de aciertos la tasa de pérdida, seguido del modelo 3 y por último el modelo 2. El mejor desempeño del primer modelo puede deberse tanto a la selección de variables (información no tradicional) como al uso de *machine learning* que es capaz de capturar relaciones no lineales entre variables. En términos de contribución, la información alternativa contribuye en un 2,2% adicional al área por debajo de la curva ROC, mientras que la aplicación de modelos de *machine learning* contribuye en un 5,3%.

Para evaluar el desempeño de los modelos frente a un shock exógeno, los autores utilizaron los datos de repago del crédito luego de un cambio regulatorio en China que derivó en menor oferta crediticia, especialmente para prestatarios riesgosos. El poder discriminatorio antes del cambio regulatorio de los modelos 1 y 3 (medido por el área debajo de las curvas ROC) es mayor al del modelo 2, y no hay diferencia estadísticamente significativa entre los primeros dos modelos mencionados. Luego del shock regulatorio, el poder discriminatorio de los tres modelos declina, aunque el modelo 1 se desempeña mejor que los restantes modelos. Al descomponer la brecha del poder discriminatorio en dos efectos, la información no tradicional representa la razón principal por la cual el modelo 1 es el de mejor desempeño previo al shock; mientras que luego del shock, la tecnología de *ML* se convierte en la principal razón. El modelo 1 se comporta mejor que el modelo 3 incluso en “tiempos normales”, pero la diferencia se acentúa luego del shock regulatorio.

Por último, el trabajo evalúa cómo evoluciona el desempeño del modelo basado en técnicas de aprendizaje automático para clientes con diferentes historiales crediticios. Para ello, se utiliza la duración de la relación cliente-banco ya que los prestatarios, por lo general, piden su primer préstamo al sector bancario. Los autores encuentran que el desempeño de los tres modelos mejora con la duración de la relación, y es interesante resaltar que la ventaja comparativa entre el modelo 1 y los demás aumenta para bajos niveles de relación cliente-banco. Contrariamente, cuando la relación se vuelve fuerte, las diferencias entre el modelo y los demás se reduce. Ello coincide con la idea de que una relación más duradera entre el banco y sus clientes tiende a atenuar los problemas de información asimétrica, lo cual se refleja también en la relación entre compañía Fintech y clientes.

En suma, los autores evidencian que tanto la información asimétrica como las técnicas de aprendizaje automático mejoran la capacidad predictiva sobre el repago de los clientes, siendo las técnicas de *machine learning* particularmente relevantes para ajustar la predicción ante

shocks externos. Además, los beneficios de los modelos basados en *ML* aumentan cuando el prestamista tiene poca información (debido a una corta relación) acerca del prestatario. Esta evidencia sugiere que los modelos no tradicionales pueden mejorar la evaluación del riesgo para prestatarios con poca información disponible, es decir, aquellos con corto o nulo historial crediticio.

Al igual que con el uso de información alternativa, uno de los mayores beneficios de los nuevos métodos es su superioridad para encontrar prestatarios con menor riesgo que el que le confieren los modelos tradicionales. Albanesi & Vamossy (2019) desarrollaron un modelo de clasificación crediticia basado en *deep learning* y encontraron que éste beneficia mayormente a consumidores con baja puntuación crediticia ya que es capaz de identificar, entre ellos, a los prestatarios con menor probabilidad de impago. Además, para tales aplicantes, cuantificaron en un 5% del saldo de la deuda (o un cuarto de la tasa de interés promedio de prestatarios con bajo puntaje crediticio) el ahorro por ser clasificados de acuerdo al modelo que desarrollaron.

Un interrogante relevante es cómo se desempeñan los modelos basados en *machine learning* frente a recesiones económicas, ya que en tal escenario las relaciones entre variables pueden cambiar y el modelo ser lento para capturar tales cambios²³. Como se mencionó previamente, Gambacorta et al. (2019) analizan el desempeño de estos modelos antes y después de un *shock* regulatorio en China que resultó ser un *shock* negativo en el mercado crediticio chino aumentando el número de préstamos impagos. El trabajo encuentra que el desempeño tanto de los modelos tradicionales como no tradicionales se deteriora después del *shock*, pero menos para los últimos. Los autores atribuyen el resultado a la no linealidad de los modelos de *machine learning*, debido a que ello hace que puedan capturar relaciones dinámicas que son más relevantes cuando el contexto externo cambia de repente.

²³ Este es un problema comúnmente conocido como *overfitting*. Significa que el modelo describe con mucha exactitud el *set* de datos con el cual fue entrenado pero falla al predecir confiablemente futuras observaciones (predicción fuera de la muestra).

A menudo se comparan los modelos de clasificación crediticia según diferentes horizontes temporales de predicción. Dado un similar desempeño en horizontes cortos (entre treinta y sesenta días), los modelos que mejores predicciones provean para horizontes más largos permitirán a los prestamistas intervenir más temprano y prevenir pérdidas si la calidad de los prestatarios se deteriora. Butaru et al. (2016) muestran que cuando los modelos se usan para predecir impagos uno o dos trimestres hacia adelante, los modelos basados en *machine learning* consiguen mejores resultados, pero los beneficios relativos son más chicos que aquellos en horizontes más cortos.

Otro tópico discutido en la literatura es si el uso de nuevos modelos ayuda a reducir la discriminación contra segmentos minoritarios en el mercado crediticio. Dobbie et al. (2021) documentan la presencia de sesgos raciales y etarios considerables en el mercado de préstamos para consumo en Reino Unido. Los autores utilizan información de un prestamista de gran tamaño que otorga préstamos de corto plazo, sin exigencia de colateral y a prestatarios de alto riesgo. El trabajo prueba la existencia de sesgos en el modelo de clasificación crediticia de la compañía, basado en la calificación por parte de un evaluador para cada aplicante, y demuestra que una regla de decisión basada en modelos de *machine learning* no solo podría eliminar tal sesgo, sino que además, aumentaría los ingresos de la empresa en un 30% en promedio.

El trabajo de Fuster et al. (2019) estudia las implicancias potenciales para diferentes grupos étnicos usando modelos basados en *machine learning* en el mercado de hipotecas de Estados Unidos. Una gran fracción de los prestatarios pertenecientes al grupo mayoritario (caucásicos no hispánicos) experimentan propensiones de impago estimadas más bajas usando tecnología de aprendizaje automático comparado con modelos logit, los cuales podrían potencialmente beneficiarse con tasas de interés más bajas. Otros grupos (particularmente los minoritarios) no consiguen el mismo nivel de mejora, con lo cual, el cambio en la tasa de interés sería menor.

3.3 Evidencia sobre la ampliación de acceso al crédito y el efecto de éste sobre el crecimiento

Los préstamos Fintech son vistos con frecuencia como una avenida innovadora para expandir el acceso al crédito y facilitar la participación en segmentos sin (o escasas) oportunidades financieras. Esta subsección trata sobre la inclusión financiera, con el común supuesto de que las Fintech ayudan a achicar la brecha crediticia para prestatarios con falta de acceso a las finanzas. La idea de que los prestamistas Fintech satisfacen una demanda crediticia insatisfecha se basa en un cuerpo emergente de investigaciones que se enfocan especialmente en mercados crediticios de economías en desarrollo.

El trabajo de Hau et al. (2018) utilizó una base de datos de 3,4 millones de pequeños vendedores de la plataforma de comercio electrónico de Alibaba para dilucidar si: 1) el crédito fintech puede actuar como sustituto de otros tipos de créditos más costosos o incluso ampliar el acceso al mismo para pequeñas empresas sin acceso a priori, 2) el crédito fintech tiene un efecto sobre el crecimiento de las empresas en el sector de *e-commerce* y 3) hay efectos heterogéneos en el crecimiento de empresas con distintas características.

Los autores encuentran que el uso del crédito *online* se relaciona sistemáticamente con fricciones crediticias relacionadas a la localización geográfica. La tasa de préstamos/PBI local se correlaciona negativamente con el uso del crédito *online* después de controlar por características de la firma y el dueño de la misma. Además, la proximidad geográfica a sucursales bancarias tiene relevancia en el uso del crédito fintech: una distancia mayor respecto a las 10 sucursales bancarias más cercanas predice un mayor incremento en el uso del crédito provisto por firmas Fintech. En otros términos, la demanda de crédito Fintech es mayor en áreas urbanas con menor oferta crediticia bancaria (relativo al PBI local) y en áreas rurales con mayor distancia entre el aplicante y la sucursal bancaria más cercana.²⁴

²⁴ Resultados similares se encuentran para Estados Unidos en Jagtiani & Lemieux (2018), quienes muestran que los préstamos Fintech para consumo personal han penetrado en áreas donde el número de sucursales bancarias ha disminuído más que en otras.

Con estos resultados, los autores concluyen que el crédito Fintech parece superar algunas de las distorsiones geográficas en el mercado crediticio chino, otorgando créditos a vendedores alocados en ciertas ubicaciones que no consiguen crédito en bancos tradicionales. Además, los autores muestran que los préstamos *online* expanden la frontera de disponibilidad crediticia a empresas chinas con bajas calificaciones y conjeturan que los préstamos Fintech aumentan el margen extensivo de crédito a vendedores con mayor riesgo crediticio ex-ante, los cuales fueron previamente excluidos por el sistema bancario tradicional.

Otro hallazgo importante es que el acceso al crédito Fintech tiene un impacto positivo y significativo sobre el crecimiento de las firmas del *e-commerce* chino. Aprovechando que la firma Fintech establece un valor mínimo de calificación interna para aprobar los créditos, los autores proveen evidencia de que la aprobación del crédito impulsa un mayor desarrollo para las firmas. En promedio, el crecimiento del volumen de ventas (precio por cantidad) y el crecimiento de transacciones (número de ventas) da un salto incremental del 13,1% y 10,6% respectivamente, en el primer mes luego de la aprobación del crédito. Si la muestra toma solo las firmas que utilizan la línea de crédito, y no todas las firmas con un crédito aprobado, el volumen de ventas crece en un 57% y la cantidad de transacciones en un 46%. Tales estimaciones se encuentran en línea con estimaciones previas de la literatura sobre el rol de las limitaciones crediticias como un importante impedimento del crecimiento en economías emergentes.

Por último, el trabajo revela restricciones significativas al crecimiento sobre las firmas más pequeñas, resultantes de las fricciones del mercado crediticio chino. Las firmas del primer cuartil de distribución de edad experimentan sobre su volumen de ventas y transacciones un crecimiento de 4,8 y 5,8 puntos porcentuales, respectivamente, más grande que sus pares del último cuartil una vez que consiguen un préstamo aprobado. Por tanto, el crédito Fintech parece ser más beneficioso para el crecimiento de corto plazo de firmas más jóvenes, lo cual es

consistente con la idea de que las *start-ups* enfrentan restricciones más pronunciadas respecto al crédito.

Como se mencionó previamente, el trabajo de Frost et al. (2019) encuentra que las compañías Fintech tienen una ventaja de información (ya sea proveniente de las bases de datos a las que accede o de los modelos de procesamiento que emplea) que les permite a sus modelos desempeñarse mejor a la hora de clasificar prestatarios. La consecuencia directa de ello es poder otorgar préstamos a aplicantes a los cuales se les negaría el crédito en el banco tradicional, u otorgarlos a un menor costo debido a una mejor evaluación de su probabilidad de impago.

Los autores buscan responder, además, si es que hay diferencias significativas en el desempeño de las firmas que reciben crédito por parte de las Fintech. Para responder el interrogante, el trabajo utiliza micro-información detallada de Mercado Libre y Ant Financial para evaluar cómo cambia el volumen de ventas y el número de productos ofrecidos por cada firma en el año siguiente a la toma del préstamo. La comparación entre Ant Financial y Mercado Libre provee la primera comparación internacional entre los microcréditos de dos empresas Fintech.

En líneas generales, y luego de varios controles para las variables de los modelos, se encuentran resultados estables. Las firmas que usaron el crédito de Mercado Libre aumentaron el número de productos ofrecidos en 71-73 puntos porcentuales en el año siguiente después de tomar el crédito comparado con las firmas a las que se les otorgó un crédito pero no lo usaron. Además, las firmas que usaron la línea de crédito vieron su volumen de ventas aumentar en 75-79 puntos porcentuales. Resultados similares se encuentran para las firmas de Ant Financial.

Sin embargo, los autores advierten que, a pesar de los controles realizados, no se pueden desestimar posibles problemas de endogeneidad. Mientras que es posible que el uso del crédito le permitiera a las firmas expandir su oferta de productos y sus ventas, es también posible que

Mercado Libre y Ant Financiamiento ofrecen créditos a las firmas que ellos prevén que vayan a crecer, y que esas firmas que esperaban crecer tomen el crédito.

Por último, el trabajo de Gambacorta (2020) encuentra que el crédito fintech no se relaciona con los precios de la vivienda, pero que sí lo hace fuertemente con las características particulares de la firma, tal como volúmen de transacciones por ejemplo. Contrariamente, tanto el crédito bancario asegurado como el no asegurado reaccionan significativamente ante los precios locales de la vivienda, lo cual puede probablemente reflejar información útil sobre las condiciones en las cuales las firmas operan y sobre su solvencia.

Tales resultados tienen implicancias macroeconómicas importantes, en tanto indican que la provisión del crédito fintech tiende a reducir la efectividad del mecanismo del acelerador financiero, ya que la provisión del crédito no está ligada al movimiento de los precios de los activos. El crédito fintech es, de hecho, menos dependiente del ciclo financiero comparado con el crédito bancario, lo cual puede tener efectos relevantes para la estabilidad del financiamiento a PyMEs. Por ejemplo, el crédito bancario podría ajustarse o expandirse en respuesta a *shocks* negativos sobre el precio de los activos, pero el crédito fintech sería menos afectado.

En resumen, una oferta crediticia que se base en análisis de datos en vez de en el uso de colateral podría tener implicancias importantes para los mecanismos de transmisión monetarios. Mientras que el mecanismo del acelerador financiero implica que los impulsos de política monetaria son transmitidos a la oferta crediticia bancaria a través del valor de los colaterales, tal canal deja de operar, o pierde relevancia, en el caso del crédito fintech.


4. El mercado crediticio en Argentina

Como ya se mencionó anteriormente, el escaso acceso al crédito y el alto costo del mismo son unos de los mayores desafíos de las economías emergentes, y Argentina no escapa a ello. El acceso al crédito de una población se relaciona estrechamente con el grado de

bancarización de la misma, siendo la bancarización un factor importante en el desarrollo y crecimiento de una economía. “La bancarización promueve la formalización, contribuye a transacciones más eficientes y seguras, reduce costos administrativos asociados a la actividad productiva y fomenta una adecuada canalización de recursos hacia aquellas inversiones productivas más competitivas” (Instituto Argentino de Análisis Fiscal, 2018).

El interés creciente en la academia y la política por la inclusión financiera derivó en el diseño de diferentes indicadores financieros. Uno de ellos es el de profundidad financiera, que remarca la incidencia de agregados financieros respecto al tamaño de la economía y se mide comúnmente por los *ratios* de cantidad de depósitos sobre PBI y volumen de crédito otorgado sobre PBI.

Gráfico 1. Créditos y depósitos sobre PIB en Argentina




Fuente: elaboración propia en base a datos del Banco Mundial

Al observar la evolución de tales *ratios* en Argentina se aprecia una tendencia creciente para ambos si se considera el período 2004-2020, lo cual se explica en parte por la contracción del sistema bancario post crisis de 2002. La recuperación económica de los años posteriores se

vio reflejada particularmente en el crecimiento de la tasa de créditos sobre PBI, hasta el año 2013 donde tal crecimiento se desaceleró y la tasa comenzó a tener un comportamiento irregular, alcanzando un máximo de 14,6% en 2017. Los depósitos, por su parte, se mantuvieron relativamente estables respecto al PBI hasta el año 2014, a partir del cual comenzaron a crecer hasta representar el 23,9% del PBI en 2020.

Gráfico 2. Depósitos sobre PIB. Comparativa de países



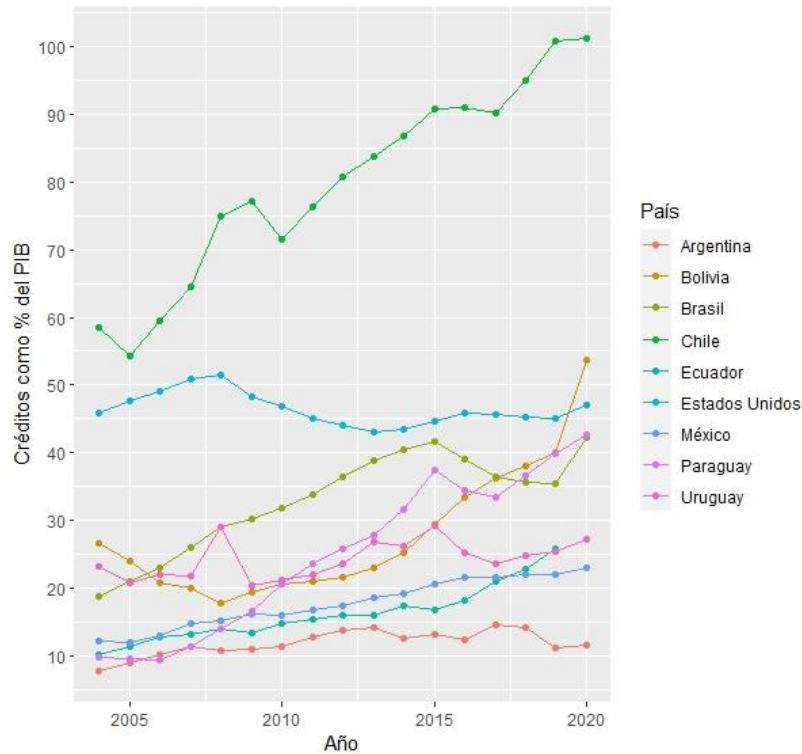
Fuente: elaboración propia en base a datos del Banco Mundial

Al realizarse la comparación de ambos *ratios* entre Argentina y el resto de los países de la región, se observa que para ambos Argentina exhibió los niveles más bajos año a año, siguiendo la misma tendencia que el resto de países. En cuanto a depósitos, la participación que éstos tienen sobre el PBI en Argentina es la mitad que en Brasil y poco más de un tercio que en Chile y Uruguay, mostrando similitud con los niveles de México.

Para el caso del crédito, las diferencias entre Argentina y el resto de países son aún mayores. La participación del mismo sobre el PBI en México o Uruguay duplica a la de Argentina, mientras que en Bolivia, Brasil y Colombia casi la cuadruplica; y en Chile es casi

ocho veces mayor. Mientras en Argentina el *ratio* de créditos/PBI fue de 11% en 2020, en México fue de 22%, en Colombia del 45% y en Chile del 100%.

Gráfico 3. Créditos sobre PIB. Comparativa de países



Fuente: elaboración propia en base a datos del Banco Mundial

Tales guarismos podrían estar evidenciando la baja bancarización, particularmente bajo acceso al crédito, de los argentinos en comparación a sus vecinos. Si bien la mayor parte de quienes acceden al crédito lo hacen a través del sector formal (24%), como en los países desarrollados, la diferencia es significativa ya que tales países exhiben niveles de casi el 60% de crédito formal según The Global Findex Database 2017.


4.1 Penetración de billeteras virtuales

El CVU es un código de 22 dígitos, similar al de las Cuentas Bancarias Uniformes (CBU), pero provisto por un Proveedor de Servicios de Pago (PSP), que permite enviar y recibir dinero entre una billetera o cuenta digital y un banco, o entre billeteras digitales. Los PSP son las

personas jurídicas que, sin ser entidades financieras, cumplen al menos una función dentro de un esquema de pagos minorista.²⁵

Si se analiza la evolución de cuentas bancarias y PSP durante los últimos cuatro años, se evidencia un crecimiento trimestre a trimestre en la cantidad de personas que posee una cuenta en alguna billetera virtual; crecimiento que se acelera a partir de junio de 2020. En marzo de 2019, 1,1 millones de personas poseían una cuenta proveída por una billetera o banco digital, sobre un total de 27,6 millones de personas con algún tipo de cuenta (bancaria o PSP), representando así el 4% del total. Para junio de 2020, las personas con una cuenta PSP pasaron a ser 5,4 millones, representando el 17% del total de personas con una cuenta (31,5 millones); y, para diciembre de 2021, las personas con una cuenta proveída por un PSP pasaron a ser 16,3 millones, representando el 49% del total de personas con algún tipo de cuenta (33,3 millones).

Gráfico 4. Tenencia de cuentas bancarias y de pago (millones de personas)



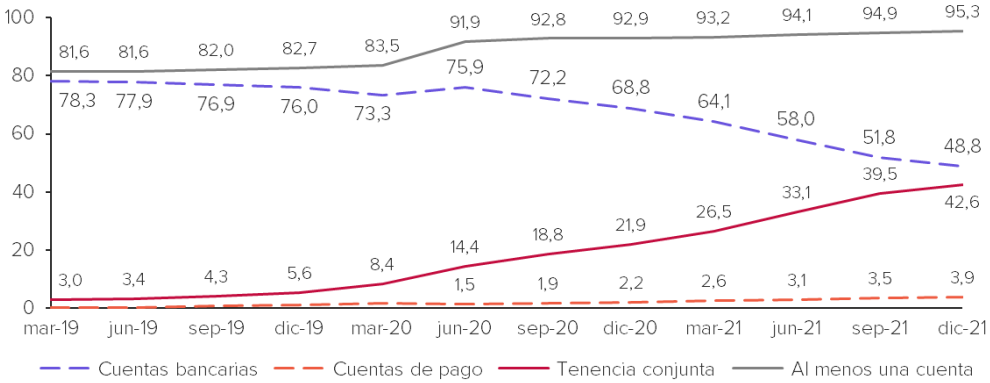
Fuente: elaboración propia en base a datos de Informe de Inclusión Financiera

Si tales números se analizan en relación a la población adulta del país, se observa un salto de nivel en la proporción de adultos con alguna cuenta a partir de junio de 2020 (83,5% en marzo de 2020 vs. 91,9% en junio de 2020). Además, crece constantemente la proporción de adultos con tenencia conjunta (cuenta bancaria y cuenta digital), partiendo de un 3% en marzo de 2019 y alcanzando un 42,6% en diciembre de 2021. Al mismo tiempo, se reduce la proporción de

²⁵ Proveedores de Servicio de Pago. Última comunicación incorporada: “A” 7495. Banco Central de la República Argentina.

adultos que cuenta únicamente con cuenta bancaria: de 78,3% en marzo de 2019 a 48,8% en diciembre de 2021.


Gráfico 5. Tenencia de cuentas bancarias y de pago (porcentaje de la población adulta)



Fuente: elaboración propia en base a datos de Informe de Inclusión Financiera

Por último, el perfil etario de las personas que poseen ambos tipos de cuenta se concentró mayormente en los adultos de mediana edad (30 a 64 años): en diciembre de 2021, una de cada dos personas del segmento en cuestión poseía ambas cuentas, mientras que casi el 100% poseía cuenta bancaria. Los jóvenes (entre 15 y 29 años) continúan siendo el segmento con mayor concentración de cuentas provistas por PSP (54,2%), mientras que los adultos mayores (65 años o más) el de menor (13,2%). Resultados similares a los reportados por Bain & Company (2017), pues a los jóvenes les resulta más natural adoptar tecnologías digitales.

Gráfico 6. Proporción de tenencia conjunta de cuentas por grupos etarios



Fuente: elaboración propia en base a datos de Informe de Inclusión Financiera

4.2 Tarjetas de crédito y líneas de microcrédito

Las tarjetas de crédito no sólo son instrumentos de pago, sino que además sirven como fuente de crédito, ya que extienden la oferta de crédito de corto plazo, incluso cuando los usuarios no pagan interés. La introducción de tarjetas de crédito podría, por lo tanto, afectar el mercado crediticio de corto plazo. Según el Banco Mundial, el 49% de los adultos en economías de altos ingresos usaron una tarjeta de crédito en 2017, mientras que en Argentina, a pesar del continuo crecimiento en el uso de tarjetas de crédito, sólo el 20% reportó haber usado una en el último año.

Sin embargo, el acceso a las tarjetas de crédito se ve condicionado por algunos factores como ingresos, antigüedad como empleado, antigüedad en el empleo actual, historial crediticio, edad, formación académica y estado civil, entre otros²⁶. Ello genera que, inevitablemente, algunos segmentos, tales como jóvenes o personas sin empleo o empleo informal, encuentren mayores dificultades respecto al resto de la población para acceder a una tarjeta de crédito.

Tal es así que, en Argentina, según datos del Banco Mundial, el 9% de los adultos jóvenes (entre 15 y 24 años) pidieron prestado a una institución financiera o tarjeta de crédito en 2017, mientras que tal porcentaje fue del 29% para mayores de 24 años. Además, el 26% de los adultos jóvenes pidieron un préstamo a familia o amigos, mientras que el 13% de los adultos mayores lo hizo a través de la misma vía. Ello evidencia la falta de acceso a préstamos formales por parte de los jóvenes, necesidad que se canaliza mayormente a través de canales informales, como familia y amigos.


En el mismo sentido, de los primeros cuatro deciles de la distribución de ingresos, el 15% pidió un préstamo en una institución bancaria o tarjeta de crédito, mientras que tal porcentaje fue del 31% para los últimos seis deciles de la distribución. Si se considera el porcentaje de personas que pidieron dinero prestado (por cualquier vía) en el último año, tal porcentaje es del 29% para

²⁶ Black, S. E., & Morgan, D. P. (1998)

el grupo de menores ingresos y de 43% para el grupo de mayores ingresos. Tales números podrían reflejar la falta de acceso crediticio en la población que se esperaría más lo necesite.

Al analizar información de una importante Fintech del mercado argentino, que no puede ser nombrada por razones de confidencialidad de la información, se observa que el 79% de sus usuarios activos de entre 15 y 24 años de edad obtuvieron una oferta de crédito, mientras que tal porcentaje fue del 85% para mayores de 24 años. Ello podría validar el hecho de que usuarios jóvenes reciben menos oferta de crédito por contar con menor historial crediticio; sin embargo, los porcentajes de oferta de crédito para ambos grupos dentro de la Fintech de estudio son mayores a los que reporta el informe del Banco Mundial y hasta se observa una menor diferencia en puntos porcentuales entre ambos grupos.

Gráfico 7. Oferta de crédito y uso del mismo por segmento de edad




Fuente: elaboración propia en base a los datos de la fintech de estudio

Las razones para observar un alto porcentaje de oferta de crédito pueden ser variadas: por un lado, puede deberse a que las fintech efectivamente cuentan con información adicional que les permite evaluar mejor que un banco el riesgo crediticio de sus clientes; por otro lado, puede que el grupo de clientes de las fintech no sea representativo de la población general (por ejemplo: puede que la empresa esté captando mayormente clientes ya bancarizados y con acceso y uso de tecnología).

Sin embargo, es importante remarcar que, de la población de usuarios con una oferta de crédito, el porcentaje de clientes que efectivamente lo utiliza es mayor entre el grupo de jóvenes (46% para jóvenes de 15 a 24 años vs. 41% para mayores de 24 años). Ello podría significar que los jóvenes tienen una menor oferta de crédito fuera de la fintech en relación al otro grupo, y por tanto, utilizan el crédito fintech en mayor proporción que los mayores de 24 años.

Gráfico 8. Oferta de crédito y uso del mismo por segmento de edad y tenencia de tarjeta de crédito



Fuente: elaboración propia en base a los datos de la fintech de estudio

Para validar la hipótesis anterior, se decidió separar a ambos grupos en relación a la tenencia de tarjeta de crédito externa a la fintech. Se observa que, de los jóvenes de 15 a 24 años, sólo el 22% tiene una tarjeta de crédito otorgada por otra institución externa a la fintech en cuestión, mientras que tal proporción es del 49% para mayores de 24 años; diferencia que es estadísticamente significativa al 99,9% de confianza. Por tanto, es de esperarse que usuarios jóvenes utilicen en mayor medida el crédito fintech por tener menos acceso al crédito fuera de la misma en comparación al grupo de mayor edad.

Además, se observan los resultados esperables en cuanto a oferta de crédito fintech para usuarios con y sin tarjeta de crédito. En ambos grupos etarios, aquellos que poseen una tarjeta de


crédito tienen mayor oferta de crédito fintech (76% vs. 88% para clientes de 15-24 años y 80% vs. 90% para mayores de 24 años), pues son usuarios con un historial crediticio previo y seguramente más informativo.

Al observar sólo usuarios con oferta de crédito fintech y analizar el porcentaje que utilizó el crédito, nuevamente se observan los resultados esperables: para cada grupo etario, aquellos que no poseen tarjeta de crédito tienen un mayor uso del crédito fintech que aquellos que sí poseen tarjeta de crédito. Por un lado, el 47% de jóvenes sin tarjeta de crédito utilizó el crédito fintech, a diferencia del 44% de jóvenes con tarjeta de crédito; por otro lado, el 46% de mayores sin tarjeta de crédito utilizó el crédito fintech, a diferencia del 36% de mayores con tarjeta de crédito.

Por último, debe resaltarse que, si bien para ambos grupos etarios la utilización de crédito fintech aumenta en usuarios sin tarjeta de crédito, no se observan diferencias significativas al comparar a los usuarios sin tarjeta de crédito por grupo etario (47% de utilización entre jóvenes de 15 a 24 años y 46% entre mayores de 24 años). Ello podría indicar que la mayor parte de la diferencia en el uso del crédito entre grupos etarios se debe a la diferencia existente entre usuarios con tarjeta de crédito entre grupos.

A continuación se divide a los usuarios en tres grupos (C, B, A), de menor a mayor nivel socioeconómico en base ciertas métricas: tenencia de tarjeta de crédito, categoría de tarjeta de crédito, productos de la fintech utilizados, renta declarada o estimada, edad, situación como deudor extraída del Banco Central (BCRA), entre otras.


Gráfico 9. Oferta de crédito y uso del mismo por nivel socioeconómico



Fuente: elaboración propia en base a los datos de la fintech de estudio

Es interesante observar que el porcentaje de oferta de crédito es mayor para el segmento C (85%) que para el B (82%), lo cual es un resultado no esperado, pues, intuitivamente, los usuarios B deberían ser menos riesgosos e incluso se debería contar con más información sobre ellos. En cuanto al uso del crédito entre usuarios con oferta, se obtienen los resultados esperados: el porcentaje de uso decrece a mayor nivel socioeconómico, siendo de más del doble la diferencia entre los grupos de menor y mayor nivel socioeconómico (58% vs. 26% respectivamente).

Gráfico 10. Oferta de crédito y uso del mismo por nivel socioeconómico y tenencia de tarjeta de crédito



Fuente: elaboración propia en base a los datos de la fintech de estudio

Si se separa a cada grupo según tenencia de tarjeta de crédito no provista por la fintech, se observa que, por la manera en que fue construido cada segmento, los usuarios del segmento C no tienen tarjeta de crédito, mientras que todos los usuarios del segmento A tienen. De los usuarios del segmento B, el 57% posee tarjeta de crédito de otra institución, siendo la oferta del crédito fintech mayor para los usuarios con tarjeta de crédito (89% vs. 72% de usuarios sin).

Al comparar el uso de crédito fintech entre segmentos C y B para usuarios sin tarjeta de crédito, se observa una diferencia estadísticamente significativa con 99,9% de confianza, siendo las proporciones de uso del 58% para usuarios del segmento C y 12% para usuarios del segmento B. Del mismo modo, al comparar entre segmentos B y A para usuarios con tarjeta de crédito, la diferencia nuevamente es estadísticamente significativa al 99,9% de confianza, siendo las proporciones de uso del 45% para usuarios del grupo B y 26% para usuarios del grupo A.

Finalmente, es interesante notar que para usuarios del segmento B, el porcentaje de uso del crédito es mayor para usuarios con tarjeta de crédito (45% vs. 12% de usuarios sin tarjeta). Las causas de ello podrían ser varias. Entre ellas, podría o bien ocurrir que haya usuarios con distintas características entre grupos (por ejemplo: usuarios B sin tarjeta de crédito podrían acceder a una pero no lo hacen porque prefieren pagar al corriente y por ende tampoco usan el crédito fintech), o bien, usuarios con tarjeta de crédito hacen uso del crédito fintech porque ofrece mejores tasas de interés que la institución que les provee la tarjeta. Sin embargo, es evidente que usuarios de menor nivel socioeconómico hacen un mayor uso del crédito fintech que los de mayor nivel socioeconómico, posiblemente explicado por el acceso al crédito por fuera de la fintech.

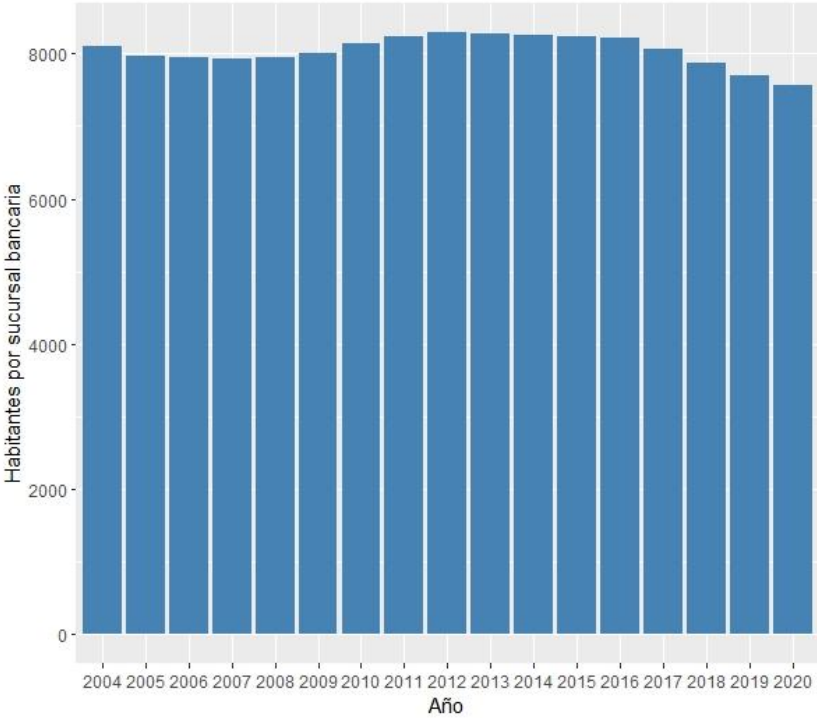
4.3 Penetración crediticia según ubicación geográfica

Un resultado interesante del trabajo de Hau et al. (2018) es que el uso del crédito *online* se relaciona sistemáticamente con fricciones crediticias relacionadas a la localización geográfica.

Como se mencionó previamente, los autores encontraron que la proximidad geográfica a sucursales bancarias tiene relevancia en el uso del crédito fintech: la demanda de crédito Fintech es mayor en áreas urbanas con menor oferta crediticia bancaria (relativo al PBI local) y en áreas rurales con mayor distancia entre el aplicante y la sucursal bancaria más cercana.

En este sentido, resulta relevante incluir medidas de acceso financiero para las provincias argentinas. Si se utilizan los datos provistos por el banco de datos del Banco Mundial y se analiza la evolución de sucursales bancarias en Argentina para el período 2004-2020, se observa un nivel estable entre 8200 y 7500 habitantes por sucursal bancaria.

Gráfico 11. Habitantes por sucursal bancaria en Argentina




Fuente: elaboración propia en base a datos del Banco Mundial

Por otra parte, el BCRA publica la cantidad de sucursales bancarias por provincia, que, junto con las estimaciones de población del Instituto Nacional de Estadísticas y Censos (INDEC), permiten construir el indicador anterior por jurisdicción. Así, la Ciudad Autónoma de Buenos Aires es el distrito con menor cantidad de habitantes por sucursal bancaria (3.767), o, lo que es lo mismo, el distrito con mayor cantidad de sucursales bancarias cada 100.000 habitantes

(26,5). Completan el podio las provincias de La Pampa y Tierra del Fuego con 4.923 y 6.999 habitantes por sucursal bancaria respectivamente. En último lugar se encuentra la provincia de Jujuy, con una sucursal cada 22.498 habitantes, precedida por Formosa y San Juan con 21.197 y 20.454 habitantes por sucursal bancaria respectivamente.

Gráfico 12. Habitantes por sucursal bancaria por provincia. Año 2021

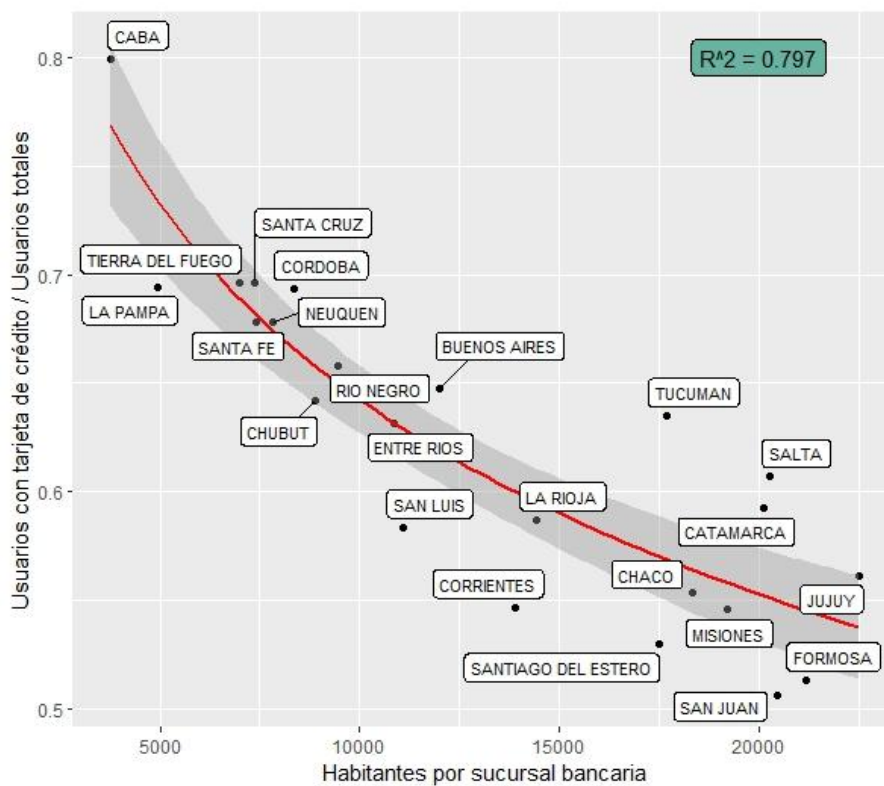


Fuente: elaboración propia en base a datos del BCRA e INDEC
 Nota: Mendoza se encuentra excluida por falta de datos respecto a cantidad de sucursales bancarias

A la luz de que la distribución de sucursales bancarias por habitantes varía significativamente entre provincias, hay valor en relacionar tal indicador con otras variables, como lo son la penetración de tarjeta de crédito o el índice de desarrollo humano (IDH). A continuación se utiliza información extraída de la fintech de estudio referida a la cantidad de usuarios con una tarjeta de crédito no provista por la fintech en relación a la cantidad de usuarios totales por provincia.

En primer lugar, puede observarse en el gráfico 13 que la penetración de tarjeta de crédito guarda una relación negativa con la cantidad de habitantes por sucursal bancaria; lo cual es esperable, pues, a menor cantidad de puntos de acceso financiero en una jurisdicción, menor es la probabilidad de que sus habitantes posean una tarjeta de crédito. Al utilizar un modelo *linear-log* para regresionar la penetración de tarjeta de crédito en base a la cantidad de habitantes por sucursal bancaria, se obtiene un modelo con un $R^2 = 0,797$

Gráfico 13. Relación entre penetración de tarjeta de crédito y habitantes por sucursal bancaria




Fuente: elaboración propia en base a datos del BCRA y fintech de estudio

Nota: Mendoza se encuentra excluida por falta de datos respecto a cantidad de sucursales bancarias

En segundo lugar, tal y como la extensa literatura lo describe, se observa, en el gráfico 14, una asociación positiva entre el índice de desarrollo humano y la penetración de tarjeta de crédito, pues, usuarios con acceso al crédito pueden tomar mejores decisiones económicas (ya sean de ahorro, inversión o consumo), lo cual deriva en mejores condiciones de vida. Si se utiliza un modelo de regresión lineal con la variable IDH como dependiente y la penetración de tarjeta de crédito como independiente, el modelo arroja un R^2 de 0,666.


Gráfico 14. Relación entre IDH y habitantes por sucursal bancaria



Fuente: elaboración propia en base a datos del BCRA y fintech de estudio

Consecuentemente, debido a que la cantidad de habitantes por sucursal bancaria pareciera explicar gran porcentaje de la variabilidad de la penetración de tarjeta de crédito, y que esta última variable pareciera explicar en buena medida la variabilidad del IDH, puede suponerse que la cantidad de habitantes por sucursal bancaria explicará gran parte de la variabilidad del IDH. Ello se verifica al regresionar el IDH en función de la cantidad de habitantes por sucursal bancaria mediante un modelo de regresión lineal cuadrático, el cual arroja un R^2 de 0,687. En definitiva, provincias con menor cantidad de sucursales bancarias por habitante exhiben un menor índice de desarrollo humano, donde una posible explicación podría provenir del menor acceso al crédito que enfrentan los habitantes con menos puntos de acceso financiero.

Gráfico 15. Relación entre IDH y habitantes por sucursal bancaria



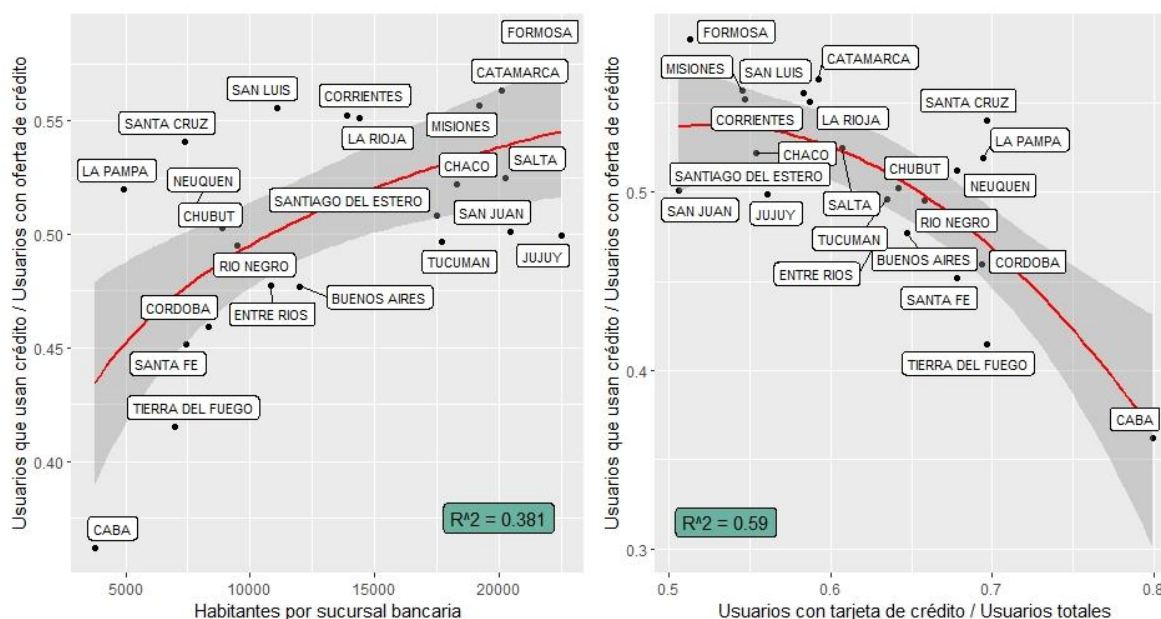
Fuente: elaboración propia en base a datos del BCRA y fintech de estudio

Nota: Mendoza se encuentra excluida por falta de datos respecto a cantidad de sucursales bancarias

Lo mencionado hasta aquí tiene particular relevancia en tanto las empresas fintech puedan actuar como sustitutas de crédito en locaciones geográficas donde las instituciones bancarias tradicionales tienen baja penetración en la población.

Utilizando información proveniente de la fintech de estudio, puede observarse una relación positiva entre habitantes por sucursal bancaria y penetración del crédito fintech, al mismo tiempo que se aprecia una asociación negativa entre esta última variable y penetración de tarjeta de crédito. Ello muestra que en provincias donde hay menos sucursales bancarias por habitante, y, consecuentemente, menos penetración de tarjetas de crédito, la penetración del crédito fintech es mayor en relación a provincias con más puntos de acceso financiero, lo cual es un resultado concordante con los hallados por Hau et al. (2018).

Gráfico 16. Relación entre penetración del crédito fintech respecto a habitantes por sucursal bancaria y penetración de tarjeta de crédito



Fuente: elaboración propia en base a datos del BCRA y fintech de estudio

Nota: Mendoza se encuentra excluida por falta de datos respecto a cantidad de sucursales bancarias

5. Conclusiones

Los avances tecnológicos modernos han permitido la creación de nuevos modelos de negocios que emplean técnicas de análisis de datos modernas sobre grandes volúmenes de información y automatizan tareas para hacer más eficientes las decisiones crediticias. Las compañías Fintech han sabido aprovechar tales avances, ofreciendo préstamos a una mayor velocidad y menor costo, garantizando préstamos a fracciones más grandes de la población, dando como resultado mayor inclusión financiera, mayor bienestar del consumidor y mayor estabilidad financiera.

De la evidencia empírica emergen algunos resultados interesantes. La información no tradicional y los modelos basados en *machine learning* mejoran la evaluación del riesgo crediticio comparados con la industria tradicional, particularmente para aquellos solicitantes con un registro crediticio escaso o nulo. Ello se refleja no solo en un mayor acceso al crédito, sino que también en un menor precio para prestatarios con un riesgo calculado impreciso.

Además, la aplicación de tales modelos tiene consecuencias macroeconómicas, pues la ampliación del crédito a pequeñas y medianas empresas previamente excluidas del mercado crediticio podría tener efectos impulsores sobre el crecimiento de las mismas. Otro resultado importante es que el crédito fintech es menos dependiente del ciclo financiero comparado con el crédito bancario, lo cual puede tener efectos relevantes para la estabilidad del financiamiento a PyMEs y para los efectos de transmisión de la política monetaria.

Por último, la conjunción de nuevos tipos de datos y modelos de aprendizaje automático consiguen mejores predicciones ex-post ante shocks exógenos y reducen sesgos raciales y etarios en el mercado crediticio.

En cuanto a la penetración crediticia, Argentina se encuentra lejos de los niveles que muestran países vecinos, con la mitad de penetración que exhibe Uruguay y un décimo de la que presenta Chile, evidenciando la baja bancarización en el país. Sin embargo, el número de adultos con algún tipo de cuenta (bancaria o fintech) ha crecido sostenidamente en los últimos tres años, particularmente de cuentas fintech.

Tales datos son alentadores, pues la evidencia de una de las fintech más grandes del país muestra que tanto jóvenes como los sectores de menores ingresos son quienes más aprovechan la oferta de crédito fintech, más aún entre usuarios que no poseen tarjeta de crédito. Además, habitantes de provincias con menos puntos de acceso financiero hacen un mayor uso del crédito fintech que aquellos habitantes con más sucursales bancarias por habitante. Esto parecería indicar que en Argentina se observa el mismo fenómeno que la evidencia recolectada por otros países: las fintech amplían el acceso al crédito tanto para segmentos postergados como para aquellos habitantes de locaciones con menor llegada del sistema bancario tradicional.

Una mayor presencia de este tipo de cuentas significa un mayor volumen de información para las empresas y, consecuentemente, una mejor valoración crediticia de los aplicantes. Sin embargo, los hacedores de política podrían incluso hacer extensivo este volumen de información

a través de iniciativas de *open-banking*, donde los usuarios pueden compartir proactivamente la información de sus cuentas entre las diferentes instituciones con las que operan, permitiendo a ciertas instituciones acceder a información a la cual hoy no acceden.

Además, otra iniciativa que mejoraría la información disponible y ampliaría el acceso al crédito sería la de permitir las transferencias estatales (por lo general a los segmentos de menores ingresos de la sociedad) hacia cuentas de pago (PSP). Según datos del Banco Mundial, los pagos digitales del sector público aumentaron la creación de cuentas bancarias ya que 11% de los tenedores de cuentas en Argentina crearon su cuenta exclusivamente para recibir transferencias del gobierno; número que aumenta hasta 25% entre los primeros cuatro deciles de la distribución de ingresos.

Concluyendo, las empresas fintech han demostrado gran capacidad para proveer créditos más baratos e incluir al mercado crediticio a segmentos previamente excluidos. Argentina tiene una baja proporción de créditos sobre el PIB en comparación con sus vecinos, lo cual tiene implicancias directas sobre el bienestar de los habitantes; sin embargo, el crecimiento de cuentas digitales podría ayudar a aumentar la oferta crediticia y por ende el bienestar de los consumidores. En este sentido, los hacedores de política podrían tomar cursos de acción para ampliar la información disponible a las entidades de crédito y para alentar el uso de cuentas digitales.

6. Referencias

- Agarwal, S., Alok, S., Ghosh, P., & Gupta, S. (2020). Financial inclusion and alternate credit scoring for the millennials: role of big data and machine learning in fintech. *Business School, National University of Singapore Working Paper, SSRN, 3507827*.
- Aggarwal, R., & Stein, P. (2016). The complex regulatory landscape for fintech: an uncertain future for small and medium-sized enterprise lending. *World Economic Forum White Paper* (Vol. 170816, pp. 1-35).
- Albanesi, S., & Vamossy, D. F. (2019). Predicting consumer default: A deep learning approach (No. w26165). *National Bureau of Economic Research*.
- Andrianaivo, M., & Kpodar, K. (2012). Mobile phones, financial inclusion, and growth. *Review of Economics and Institutions, 3*(2), 30.
- Bain & Company (2017). Evolving the customer experience in banking.
- Banco Central de la República Argentina (2022): Informe de inclusión financiera. Ciudad Autónoma de Buenos Aires, 29 de abril de 2022.
- Banerjee, A. V., & Newman, A. F. (1993). Occupational choice and the process of development. *Journal of political economy, 101*(2), 274-298.
- Bazarbash, M. (2019). Fintech in financial inclusion: machine learning applications in assessing credit risk. *International Monetary Fund*.
- Berendt, B., & Preibusch, S. (2014). Better decision support through exploratory discrimination-aware data mining: foundations and empirical evidence. *Artificial Intelligence and Law, 22*(2), 175-209.
- Berg, T., Burg, V., Gombović, A., & Puri, M. (2020). On the rise of fintechs: Credit scoring using digital footprints. *The Review of Financial Studies, 33*(7), 2845-2897.
- Black, S. E., & Morgan, D. P. (1998). Risk and the democratization of credit cards (No. 9815). *New York: Federal Reserve Bank of New York*.

- Butaru, F., Chen, Q., Clark, B., Das, S., Lo, A. W., & Siddique, A. (2016). Risk and risk management in the credit card industry. *Journal of Banking & Finance*, 72, 218-239.
- De Roure, C., Pelizzon, L., & Tasca, P. (2016). How does P2P lending fit into the consumer credit market?. *Bundesbank Discussion Paper No. 30/2016*.
- Demirguc-Kunt, A., Klapper, L., Singer, D., & Ansar, S. (2018). The Global Findex Database 2017: Measuring financial inclusion and the fintech revolution. *World Bank Publications*.
- Dobbie, W., Liberman, A., Paravisini, D., & Pathania, V. (2021). Measuring bias in consumer lending. *The Review of Economic Studies*, 88(6), 2799-2832.
- Du Toit, G., Burns, M., de Gooyer, C., & Phillips, D. (2017). Evolving the customer experience in banking. *Boston, MA: Bain & Company*.
- Frost, J., Gambacorta, L., Huang, Y., Shin, H. S., & Zbinden, P. (2019). BigTech and the changing structure of financial intermediation. *Economic Policy*, 34(100), 761-799.
- Fuster, A., Plosser, M., Schnabl, P., & Vickery, J. (2019). The role of technology in mortgage lending. *The Review of Financial Studies*, 32(5), 1854-1899.
- Galor, O., & Zeira, J. (1993). Income distribution and macroeconomics. *The review of economic studies*, 60(1), 35-52.
- Gambacorta, L., Huang, Y., Li, Z., Qiu, H., & Chen, S. (2020). Data vs collateral. *BIS Working Papers No 881*.
- Gambacorta, L., Huang, Y., Qiu, H., & Wang, J. (2019). How do machine learning and non-traditional data affect credit scoring? New evidence from a Chinese fintech firm.
- Ghosh, S. (2016). Does mobile telephony spur growth? Evidence from Indian states. *Telecommunications Policy*, 40(10-11), 1020-1031.
- Gosavi, A. (2018). Can mobile money help firms mitigate the problem of access to finance in Eastern sub-Saharan Africa?. *Journal of African Business*, 19(3), 343-360.

- Haddad, C., & Hornuf, L. (2019). The emergence of the global fintech market: Economic and technological determinants. *Small business economics*, 53(1), 81-105.
- Hau, H., Shan, H., & Sheng, Z. (2018). Fintech credit, financial inclusion and entrepreneurial growth. *Unpublished working paper*.
- Honohan, P. (2007). Cross-country variation in household access to financial services. Paper prepared for the World Bank conference on Access to Finance in Washington, DC Retrieved on July 10, 2008.
- Huang, Y., Lin, C., Sheng, Z., & Wei, L. (2018). FinTech credit and service quality. *Geneva Financial Research Institute, Working Papers, Geneva*.
- Instituto Argentino de Análisis Fiscal (2018). La formalización de las transacciones en una economía actual. *Informe sin publicar*. Córdoba, Argentina.
- International Monetary Fund (2018). The Bali Fintech Agenda. *IMF Policy Papers*.
- Jack, W., & Suri, T. (2011). Mobile money: The economics of M-PESA (No. w16721). *National Bureau of Economic Research*.
- Jagtiani, J., & Lemieux, C. (2017). Fintech lending: Financial inclusion, risk pricing, and alternative information.
- Jagtiani, J., & Lemieux, C. (2018). Do fintech lenders penetrate areas that are underserved by traditional banks?. *Journal of Economics and Business*, 100, 43-54.
- Jagtiani, J., & Lemieux, C. (2019). The roles of alternative data and machine learning in fintech lending: evidence from the LendingClub consumer platform. *Financial Management*, 48(4), 1009-1029.
- Liberti, J. M., & Petersen, M. A. (2019). Information: Hard and soft. *Review of Corporate Finance Studies*, 8(1), 1-41.
- Mbiti, I., & Weil, D. (2011). Mobile Banking: The Impact of M-Pesa in Kenya. *NBER Working Paper Series No. 17129*. 1050 Massachusetts Avenue. Cambridge, MA, 2138.

- Mishkin, F. S. (2007). *The economics of money, banking, and financial markets*. Pearson education.
- Mookerjee, R., & Kalipioni, P. (2010). Availability of financial services and income inequality: The evidence from many countries. *Emerging Markets Review*, 11(4), 404-408.
- Morawczynski, O. (2009). Exploring the usage and impact of “transformational” mobile financial services: the case of M-PESA in Kenya. *Journal of Eastern African Studies*, 3(3), 509-525.
- Moscatelli, M., Parlapiano, F., Narizzano, S., & Viggiano, G. (2020). Corporate default forecasting with machine learning. *Expert Systems with Applications*, 161, 113567.
- Park, C. Y., & Mercado Jr, R. (2018). Financial inclusion, poverty, and income inequality. *The Singapore Economic Review*, 63(01), 185-206.
- Porta, R. L., Lopez-de-Silanes, F., Shleifer, A., & Vishny, R. W. (1998). Law and finance. *Journal of political economy*, 106(6), 1113-1155.
- Rau, P. R. (2020). Law, trust, and the development of crowdfunding. *Trust, and the Development of Crowdfunding (July 1, 2020)*.
- Sahay, R., Čihák, M., N'Diaye, P., & Barajas, A. (2015). Rethinking financial deepening: Stability and growth in emerging markets. *Revista de Economía Institucional*, 17(33), 73-107.
- Sahay, M. R., Cihak, M., N'Diaye, M. P., Barajas, M. A., Mitra, M. S., Kyobe, M. A., & Yousefi, M. R. (2015). *Financial inclusion: can it meet multiple macroeconomic goals?*. International Monetary Fund.
- Tang, H. (2019). Peer-to-peer lenders versus banks: substitutes or complements?. *The Review of Financial Studies*, 32(5), 1900-1938.
- Tirole, J. (2010). *The theory of corporate finance*. Princeton university press.