


# PAPELES DE ECONOMÍA ESPAÑOLA

---



**LA GESTIÓN DE LA INFORMACIÓN EN BANCA:  
DE LAS FINANZAS DEL COMPORTAMIENTO  
A LA INTELIGENCIA ARTIFICIAL**

 **funcas**

PAPELES DE ECONOMÍA ESPAÑOLA es una revista que edita trimestralmente Funcas. La revista pretende ofrecer una información rigurosa y responsable de los problemas económicos españoles. Cinco son los criterios a los que PAPELES DE ECONOMÍA ESPAÑOLA desea ajustar su contenido.

- La plena libertad intelectual de quienes colaboran en sus páginas.
- La responsabilidad de las opiniones emitidas y el respaldo riguroso de las afirmaciones realizadas mediante datos y pruebas que avalen los planteamientos efectuados y las soluciones propuestas.
- El compromiso de las opiniones con los problemas planteados. La economía española se encuentra ante uno de los mayores retos de su historia, y dar opiniones comprometidas en estos momentos es obligación ineludible de los profesionales más cualificados.
- La búsqueda y la defensa de los intereses generales en los problemas planteados.
- La colaboración crítica de los lectores, para que nuestros Papeles se abran al diálogo y la polémica, si fuera preciso, para buscar soluciones a problemas de la economía española.

PAPELES DE ECONOMÍA ESPAÑOLA se ofrece como un medio de expresión a cuantos se interesen por nuestros temas económicos, cumpliendo con el único requisito de la previa aceptación de las colaboraciones remitidas por el Consejo de Redacción que, sin embargo, respetuoso con la libertad intelectual no modificará las ideas, opiniones y juicios expresados por los autores ni tampoco se solidarizará con ellas.

PAPELES DE ECONOMÍA ESPAÑOLA está abierta a la colaboración de todos los investigadores que deseen aportar sus trabajos sobre temas referentes a la economía española. Los envíos de originales deberán hacerse al Departamento de Edición y Documentación de Funcas, Caballero de Gracia, 28. 28013 Madrid.

PAPELES  
DE ECONOMÍA ESPAÑOLA

162

---

2019

ISSN: 0210-9107



#### PATRONATO

|                                                               |                                  |
|---------------------------------------------------------------|----------------------------------|
| ISIDRO FAINÉ CASAS<br>( <i>Presidente</i> )                   | Carlos Egea Kravel               |
| JOSÉ MARÍA MÉNDEZ ÁLVAREZ-CEDRÓN<br>( <i>Vicepresidente</i> ) | MIGUEL ÁNGEL ESCOTET ÁLVAREZ     |
| FERNANDO CONLLEDO LANTERO<br>( <i>Secretario</i> )            | AMADO FRANCO LAHOZ               |
|                                                               | MANUEL MENÉNDEZ MENÉNDEZ         |
|                                                               | PEDRO ANTONIO MERINO GARCÍA      |
|                                                               | ANTONIO PULIDO GUTIÉRREZ         |
|                                                               | VÍCTORIO VALLE SÁNCHEZ           |
|                                                               | GREGORIO VILLALABEITIA GALARRAGA |

#### PAPELES DE ECONOMÍA ESPAÑOLA

##### DIRECTORES

Eduardo Bandrés Moliné  
José Félix Sanz Sanz

##### CONSEJO DE REDACCIÓN

|                                                     |                      |
|-----------------------------------------------------|----------------------|
| CARLOS OCAÑA PÉREZ DE TUDELA<br>( <i>Director</i> ) | ELISA CHULIÁ RODRIGO |
| SANTIAGO CARBÓ VALVERDE                             | JUAN JOSÉ GANUZA     |
|                                                     | RAYMOND TORRES       |

##### COORDINADORA DE EDICIÓN Y DOCUMENTACIÓN

Myriam González Martínez

##### PORTADA

Funcas

##### EDITA

Funcas  
Caballero de Gracia, 28. 28013 Madrid

##### IMPRIME

Advantia Comunicación Gráfica

|                                |                                                  |
|--------------------------------|--------------------------------------------------|
| Depósito legal:                | M. 402-1980                                      |
| ISSN:                          | 0210-9107                                        |
| Precio del número impreso:     | 20 €                                             |
| Versión digital:               | Gratuita                                         |
| Periodicidad:                  | Trimestral                                       |
| Materia:                       | Economía Financiera                              |
| Disponible en formato digital: | <a href="http://www.funcas.es">www.funcas.es</a> |



© FUNCAS. Todos los derechos reservados. Queda prohibida la reproducción total o parcial de esta publicación, así como la edición de su contenido por medio de cualquier proceso reprográfico o fónico, electrónico o mecánico, especialmente imprenta, fotocopia, microfilm, *offset* o mimeógrafo, sin la previa autorización escrita del editor.



**«La gestión de la información en banca: de las finanzas del comportamiento a la inteligencia artificial»**

Coordinado por Santiago Carbó Valverde y Francisco Rodríguez Fernández

## SUMARIO

### INTRODUCCIÓN EDITORIAL

#### **La gestión de la información en banca: de las finanzas del comportamiento a la inteligencia artificial**

V

### COLABORACIONES

#### **I. DISRUPCIONES, FACTORES DE COMPORTAMIENTO Y TECNOLOGÍA**

|                                                                                                              |    |                                                                |
|--------------------------------------------------------------------------------------------------------------|----|----------------------------------------------------------------|
| La banca frente a la disrupción digital:                                                                     | 2  | <i>Xavier Vives</i>                                            |
| Patrones de acceso a la banca digital: aproximaciones tradicionales, aprendizaje automático y neuroeconomía: | 14 | <i>Santiago Carbó Valverde y Francisco Rodríguez Fernández</i> |
| Visiones actuales sobre el crédito <i>peer-to peer online</i> : la evidencia de China:                       | 27 | <i>Iftekhar Hasan<br/>Qing He y<br/>Haitian Lu</i>             |
| Sesgos de comportamiento en los mercados de crédito:                                                         | 48 | <i>David Peón</i>                                              |

#### **II. LA NUEVA GESTIÓN DE LA INFORMACIÓN BANCARIA**

|                                                                                                                                 |     |                                                                  |
|---------------------------------------------------------------------------------------------------------------------------------|-----|------------------------------------------------------------------|
| Retos para la gestión de la información financiera en una economía digitalizada: la perspectiva de las autoridades financieras: | 66  | <i>José Manuel Marqués<br/>Sergio Gorjón y<br/>Ana Fernández</i> |
| Las nuevas oportunidades de <i>big data</i> para las instituciones financieras:                                                 | 78  | <i>Pedro Galeano y<br/>Daniel Peña</i>                           |
| Fronteras del <i>big data</i> para el análisis económico y financiero en banca:                                                 | 98  | <i>Jesús Lozano<br/>Tomas Rodrigo y<br/>Jorge Sicilia</i>        |
| <i>Big data</i> : una visión desde los mercados financieros y la gestión de carteras:                                           | 117 | <i>David Cano</i>                                                |

### III. EXPERIENCIAS Y CASOS

|                                                                               |     |                                    |
|-------------------------------------------------------------------------------|-----|------------------------------------|
| La nueva tecnología bancaria: aplicaciones, adopción e impacto en banca:      | 126 | <i>Pedro Cuadros Solas</i>         |
| Una aproximación a las finanzas descentralizadas:                             | 141 | <i>Jesús Pérez</i>                 |
| Aplicaciones de la inteligencia artificial a los mercados financieros:        | 148 | <i>Igor Alonso y Adrián Carrio</i> |
| La identificación electrónica: redefiniendo las reglas del sector financiero: | 162 | <i>Iván Nabalón</i>                |

# LA GESTIÓN DE LA INFORMACIÓN EN BANCA: DE LAS FINANZAS DEL COMPORTAMIENTO A LA INTELIGENCIA ARTIFICIAL

## INTRODUCCIÓN EDITORIAL

AUNQUE de forma implícita el uso de la información ha sido una constante en los estudios económicos en perspectiva histórica, su tratamiento más explícito viene siendo uno de los aspectos fundamentales del análisis de oferta y demanda desde hace más de 70 años. Friedrich Hayek se refería ya al uso de la información en 1945 como mecanismo que, de forma descentralizada, ordenaba los precios y los recursos. Desde entonces, la información asimétrica se convirtió en uno de los elementos clave que explica diversas estructuras de mercado y mecanismos de ajuste, en los que los aspectos financieros han tenido un papel central y han sido objeto de múltiples aplicaciones. George Akerlof, Michael Spence o Joseph Stiglitz, entre otros, han dedicado gran parte de sus contribuciones a las asimetrías de información y sus consecuencias.

No puede obviarse, en todo caso, que en los últimos años el tratamiento de la información ha sido objeto de un interés renovado en el que la banca y las finanzas han tenido, de nuevo, notable protagonismo. Se ha revelado, cada vez de forma más patente, que para alcanzar nuevas metas de eficiencia e inclusión social, las economías modernas deben alcanzar una comprensión multidisciplinar del tratamiento de los datos. Todo ello, en un momento en el que puede producirse y gestionarse un volumen de información (*big data*) sin precedentes y, sin embargo, seguimos guiándonos por patrones de actuación que revelan importantes sesgos de comportamiento, desafiando la racionalidad de un amplio número de decisiones económicas. Se trata de patrones que, entre otras cosas, explicaron buena parte de la llamada Gran Recesión y que siguen atenazando y amenazando la estabilidad financiera en distintas dimensiones. Desde la computación hasta el análisis de actividad neuronal, pasando por un amplio espectro de estudios experimentales, los estudios interdisciplinares están abriendo nuevas vías de comprensión de la generación y gestión de la información. Y parece que se trata, a pesar de los múltiples avances, de una fase incipiente de una nueva revolución informativa.

En este número de PAPELES DE ECONOMÍA ESPAÑOLA se pasa revista a estas cuestiones con tres grandes bloques de contribuciones. El primero se dedica a explicar qué factores están propiciando nuevas

**LOS ESTUDIOS  
INTERDISCIPLINARES  
ESTÁN ABRIENDO  
NUEVAS VÍAS DE  
COMPREENSIÓN DE  
LA GENERACIÓN  
Y GESTIÓN DE LA  
INFORMACIÓN**

disrupciones tecnológicas en torno a la información en el sector financiero. El segundo analiza, de forma más específica, lo que podría denominarse la nueva gestión de la información en banca, con el *big data* como elemento central. El tercer y último bloque se dedica a experiencias y casos de estudio del tratamiento actual de la información en finanzas.

## DISRUPCIONES, FACTORES DE COMPORTAMIENTO Y TECNOLOGÍA

La primera contribución del volumen de **Xavier Vives**, presenta la disrupción digital en la banca como una forma de superar las asimetrías de información (mediante el *big data* y las técnicas de inteligencia artificial). Como punto de partida, se señala que la banca avanzará hacia un modelo centrado en el cliente que plantea desafíos formidables. Se plantea que los bancos tradicionales deberán llevar a cabo una profunda reestructuración y se producirá la consolidación. Afrontan el dilema sobre si competir cara a cara o cooperar con los nuevos participantes. En el caso de las *fintech*, este dilema se resuelve mediante su adquisición o estableciendo asociaciones con ellas. En el caso de las *bigtech*, los operadores tradicionales afrontan una situación potencialmente más delicada. La principal amenaza para ellos es que las *bigtech* intenten controlar la interfaz con los clientes mediante su superioridad en base de clientes (datos) gracias a su papel de guardabarreras en la distribución de productos financieros.

Algunos bancos, conscientes de esta amenaza, ofrecen plataformas abiertas que pueden incorporar productos de otros proveedores financieros, o han establecido asociaciones con las *bigtech*. En cualquier caso, los operadores tradicionales cuentan con algunas fortalezas que pueden aprovechar, como la confianza de los clientes para mantener a salvo sus datos, así como su conocimiento acumulado sobre la gestión de la complejidad y los marcos regulatorios restrictivos. Los operadores tradicionales que consigan prosperar serán los que logren pasar del *mainframe* a la nube, tengan pocas sucursales y mucho capital humano, y o bien se conviertan en plataformas digitales para mantener la interfaz con el cliente, o bien cuenten con productos exclusivos en las plataformas de distribución a los clientes.

**ALGUNOS  
BANCOS OFRECEN  
PLATAFORMAS  
ABIERTAS QUE  
PUEDEN INCORPORAR  
PRODUCTOS DE  
OTROS PROVEEDORES  
FINANCIEROS, O  
HAN ESTABLECIDO  
ASOCIACIONES CON  
LAS BIGTECH**

Señala **Vives** que, en la medida en que las tecnologías de filtrado, operativa simplificada y menor apalancamiento sean los principales motores de la entrada de las *bigTech*, se producirá un aumento de la eficiencia y de la inclusión financiera en el sector financiero. Este efecto será especialmente pronunciado si, en respuesta a su entrada, los operadores tradicionales mejoran su eficiencia mediante reestructu-



raciones y la adopción de tecnologías más avanzadas. No obstante, si las fuerzas que impulsan la entrada de las *bigTech* giraran en torno al poder de mercado, el aprovechamiento de las lagunas regulatorias y los efectos de arrastre de externalidades de red con fines de exclusión, entonces la eficiencia del sistema bancario podría resultar mermada en el largo plazo.

En todo caso, los reguladores deberán mantener unas condiciones equitativas entre participantes en el mercado, potenciando la innovación y manteniendo la estabilidad. Sin embargo, mantener unas condiciones equitativas es algo más fácil de decir que de hacer, atendiendo a la asimetría existente en los requisitos de intercambio de información de clientes en la banca abierta. Asimismo, los reguladores también deberán estar en alerta ante las nuevas formas de riesgo sistémico. Por ejemplo, si la banca evolucionara hacia un sistema basado en plataformas, el riesgo de que se planteen problemas sistémicos derivados de ciberataques y filtraciones masivas de datos pasará a un primer plano.

En el artículo de **Santiago Carbó Valverde** y **Francisco Rodríguez Fernández** se ilustran cómo diferentes aproximaciones a los datos pueden arrojar luz sobre un fenómeno de considerable relevancia económica y social: ¿cómo adoptan los consumidores los servicios financieros digitales? Cuantitativamente, 4.000 millones de personas en todo el mundo acceden a servicios *online* y los financieros y bancarios se encuentran entre los más destacados. Como otros fenómenos económicos, las decisiones sobre con qué grado de digitalización se deben realizar las actividades financieras no son únicamente una cuestión de demanda y de análisis de las preferencias reveladas. Estas decisiones están también significativamente influidas (si no orientadas) por variables de la oferta: los medios y canales tecnológicos que las entidades financieras ponen a disposición de los clientes y el modo en que estos responden a sus necesidades. Conocer qué quiere realmente el cliente y diseñar una oferta digital financiera que produzca ganancias de bienestar (menos costes y mejores servicios para todos) deviene extraordinariamente relevante. Se producen cada día millones de datos que deben ser sistematizados y que escapan al análisis convencional basado en encuestas para muestras limitadas y con un número reducido de variables para su adecuado tratamiento estadístico. Hoy es posible ordenar cantidades ingentes de datos y, sobre todo, de obtenerlos de nuevas fuentes, lo que da lugar a un número de variables muy elevado. En este artículo se trata de arrojar luz sobre las posibles aportaciones para aproximar las decisiones de digitalización financiera desde dos perspectivas. La primera se refiere a la profundidad de los datos y la capacidad para identificar, mediante

**LA CONSCIENCIA  
SOBRE LA VARIEDAD  
DE LOS SERVICIOS  
DIGITALES  
DISPONIBLES Y  
LA CONSULTA DE  
INFORMACIÓN  
FINANCIERA *ONLINE*  
SON PASOS PREVIOS  
AL USO FRECUENTE  
DE LOS MEDIOS  
DIGITALES PARA LAS  
TRANSACCIONES  
FINANCIERAS**

el aprendizaje automático (*machine learning*), patrones de comportamiento. La segunda se refiere a la profundidad del comportamiento y la capacidad de la neuroeconomía para revelar factores determinantes de las decisiones de digitalización financiera que tienen un origen distintivo cerebral.

El análisis resume algunas de las investigaciones amplias que se están desarrollando en el seno del Observatorio de la Digitalización Financiera (ODF) de Funcas, con aplicaciones al caso español. Los resultados del análisis de aprendizaje automático sugieren que la consciencia sobre la variedad de los servicios digitales disponibles y la consulta de información financiera *online* son pasos previos al uso frecuente de los medios digitales para las transacciones financieras. En cuanto al análisis relativo a la activación cerebral, se encuentra que existen patrones biológicos con un desarrollo particularmente activo entre la población que más intensamente canales digitales para sus transacciones financieras.

En un tiempo en el que los proveedores de servicios financieros se esfuerzan por adecuar su oferta a los cambios en la demanda y en el que existe una apuesta decidida por una agenda digital, aportar nuevas vías para entender el camino por el cual los ciudadanos optan por la digitalización en cuestiones tan trascendentes como sus operaciones financieras se antoja de significativo interés científico y utilidad social.

La tercera contribución se dedica a combinar uno de los casos más llamativos de disrupción en los mercados de crédito (los préstamos entre particular o P2P) y lo que ello supone para la concepción tradicional de la intermediación financiera. El artículo de **Iftekhar Hasan, Qing He y Haitian Lu** trata estas cuestiones. Se revisa la creciente literatura empírica sobre el crédito *peer-to-peer*, con el objetivo de obtener nuevas perspectivas a partir de los datos. Asimismo, se analiza el mercado chino de crédito *peer-to-peer*, utilizando tanto datos a nivel de plataforma-mes procedentes de 735 portales P2P como datos a nivel de transacción obtenidos a partir de una plataforma P2P líder en China, RRD. Esta revisión sugiere que el interés académico sobre el crédito P2P en la última década se focaliza en la comprensión de: (1) el comportamiento de los inversores y cómo procesan la información; (2) el diseño óptimo del mecanismo en las plataformas *peer-to-peer* (P2P); y (3) la interrelación existente entre el crédito P2P y la financiación bancaria. Observamos que las teorías económicas sobre contratación, asimetría de información y selección adversa proporcionan una herramienta útil para comprender el mercado de crédito *peer-to-peer*. De forma similar a los bancos, los particulares que actúan como prestamistas también buscan señales de calidad sobre el prestatario

basadas en información tanto «dura» como «blanda», si bien exhiben sesgos psicológicos. Las plataformas P2P, por su parte, están experimentando y optimizando su diseño de mecanismos para maximizar el volumen de contratación y reducir las tasas de impago. Hasta ahora, la evidencia empírica respalda más una relación de «sustitución» que de «complementariedad» entre el crédito P2P y el crédito bancario.

Los autores realizan un examen del mercado de crédito P2P chino que muestra que, comparadas con las plataformas P2P en normal funcionamiento, las plataformas fallidas son, en promedio, más pequeñas, tienen un menor número de inversores y tienden a ofrecer préstamos con vencimientos más cortos pero a tipos de interés más altos (para atraer inversores). Por otro lado, las plataformas fallidas suelen tener una base inversora altamente concentrada y prestatarios grandes. Esta evidencia es consistente con la idea de que, a diferencia de sus homólogos en Estados Unidos, muchas plataformas P2P pequeñas en China son bancos en la sombra y no meros «intermediarios de información». La quiebra masiva de plataformas en China se debe a la selección adversa, la falta de supervisión regulatoria, una incorrecta gestión del riesgo y casos de fraude.

Asimismo, el estudio utiliza datos a nivel de transacción procedentes de una plataforma de crédito P2P china representativa que imita el diseño de mecanismo de Prosper Marketplace. En línea con las expectativas, la calificación de crédito del prestatario, su nivel de ingresos y el nivel de formación académica son variables que predicen su éxito en la búsqueda de financiación (correlación positiva), mientras que predicen inversamente su impago (correlación negativa). Además, se encuentra que el entorno institucional de la provincia de procedencia del prestatario es relevante: un mayor desarrollo financiero y un *stock* de capital social más elevado predicen positivamente el éxito en la financiación y negativamente el impago. Esta evidencia es consistente con prestamistas racionales a nivel colectivo que tienen en cuenta información tanto «dura» (elaborada) como «blanda» (no elaborada) al tomar decisiones de inversión.

La última contribución de este bloque introductorio estudia también los mercados de crédito, en este caso para analizar los factores de comportamiento de naturaleza psicológica y su efecto en los mismos. Se trata del artículo de **David Peón**. Indica el autor que la gestión de la información ha sido y es un elemento central en el negocio bancario. Sin embargo, y pese a todo el conocimiento acumulado en el campo de la economía de la información, es un ámbito con importantes retos de futuro. Los autores se centran en el papel que los sesgos de comportamiento, identificados en décadas de investigación en la

**LA QUIEBRA MASIVA DE PLATAFORMAS EN CHINA SE DEBE A LA SELECCIÓN ADVERSA, LA FALTA DE SUPERVISIÓN REGULATORIA, UNA INCORRECTA GESTIÓN DEL RIESGO Y CASOS DE FRAUDE**

rama de las finanzas conductuales, tienen sobre la amplificación de los ciclos de crédito bancario.

Se repasan los principales modelos teóricos de la literatura conductual, que analizan el impacto de la racionalidad limitada de los agentes económicos (modelos de demanda) o de las propias entidades financieras (modelos de oferta) en la formación de burbujas de crédito. Señala **Peón** que el tipo más frecuente de anomalía observada es la combinación de un sesgo optimista y la ausencia de posibilidades de arbitraje para la banca racional, que conduce a un exceso de crédito concedido por la industria. En los modelos de demanda, reconocer el riesgo real de las innovaciones financieras, como las titulizaciones hipotecarias, requiere tiempo, lo cual conduce a los agentes a amplificar el ciclo crediticio. En los modelos de oferta, son los directivos de algunas entidades financieras quienes muestran distintos sesgos de comportamiento (principalmente, optimismo/pesimismo, exceso o defecto de confianza, disponibilidad y memoria limitada). Ello conduce igualmente a la amplificación del ciclo crediticio, siendo estos resultados robustos a distintas modelizaciones de la competencia bancaria (competencia espacial, competencia oligopolística y economía institucional).

La principal conclusión del autor es que todos los modelos conductuales propuestos confirman el impacto sistemático de los sesgos optimistas en las fases alcistas del ciclo a la hora de amplificar el auge del crédito. Asimismo, que algunos modelos anticipan que los nichos de peor calidad (ej. mercados *subprime*) son los más sensibles a la presencia de sesgos de comportamiento. Finalmente, se señala también que a pesar de que los procesos de consolidación bancaria tienen su fundamento, una excesiva concentración bancaria puede ser cuestionable si hace al mercado más sensible a los sesgos de algunas entidades.

### LA NUEVA GESTIÓN DE LA INFORMACIÓN BANCARIA

No puede obviarse que los cambios señalados en el tratamiento de la información con la digitalización requieren de un adecuado tratamiento regulatorio. A estos aspectos se dedica el artículo de **José Manuel Marqués, Sergio Gorjón y Ana Fernández**. Destacan los autores que una de las facetas más destacadas del sector financiero en la actualidad es la relacionada con la distribución y explotación de un tipo de información que si bien, históricamente, custodiaban las entidades financieras en exclusiva, por diversas circunstancias, comienza a estar disponible para amplios colectivos de competidores potenciales. Este contexto plantea diversos desafíos para los actores ya asentados, incluyendo la necesidad de tener que acometer ajustes

técnicos y organizativos de carácter complejo y costoso o la urgencia de encontrar fórmulas que aseguren su supervivencia. Se sugiere que un adecuado análisis de coste/beneficio debería obligar a iniciar una reflexión seria sobre los posibles puntos de fricción que aconsejarían una actuación pública perentoria.

Los autores indican que una posible hoja de ruta podría contemplar aspectos tales como el desarrollo de un marco normativo que ponga límites al atesoramiento de información de carácter estratégico o que fomente su mayor circulación intersectorial. También podría prestar atención a la necesidad de resolver los conflictos de interés con origen en la gestión de una plataforma y su uso para la comercialización directa de servicios propios. Asimismo, sería precisa una solución efectiva para otras cuestiones como las relacionadas con la privacidad, la seguridad nacional o la frontera entre lo que es un dato procesado y lo que no lo es.

Una de las conclusiones fundamentales es que estos aspectos incorporan importantes problemas de orden práctico de difícil resolución y obligan, además, a tener que adoptar un enfoque cooperativo de carácter tanto transversal como transnacional que se haga eco del alcance real del fenómeno subyacente. Como evaluación general, los autores señalan que las autoridades financieras están llamadas a acometer profundas adaptaciones internas que permitan tanto favorecer la extensa explotación de los datos digitales en la industria financiera como sacar un provecho directo de los mismos para la mejora del desempeño de sus funciones legales. Consideran que se trata de un proceso lento marcado por las cautelas que han de presidir cualquier cambio en el ámbito de los servicios públicos, pero donde ya se están produciendo avances notables en términos de frecuencia y granularidad de la información que se analiza o de facilitar la eliminación de ambigüedades en la interpretación de las normas.

El tratamiento de grandes datos (*big data*) es una clave esencial en este nuevo entorno de gestión bancaria. En su artículo **Pedro Galeano** y **Daniel Peña** sugieren que, por primera vez en la historia de la humanidad existen, en la mayoría de los países, datos abundantes, accesibles y con bajo coste, sobre muchos aspectos del comportamiento de los ciudadanos y que muchos de estos datos se han generado automáticamente, por el uso de dispositivos digitales conectados a Internet, especialmente teléfonos móviles, o por sensores y escáneres que los recogen.

Como ejemplo señalan el caso de Google, para la que ocho de sus servicios cuentan con más de 1.000 millones de usuarios, una proporción

**LAS AUTORIDADES  
FINANCIERAS  
ESTÁN LLAMADAS  
A ACOMETER  
PROFUNDAS  
ADAPTACIONES  
INTERNAS QUE  
PERMITAN TANTO  
FAVORECER  
LA EXTENSA  
EXPLOTACIÓN DE LOS  
DATOS DIGITALES  
EN LA INDUSTRIA  
FINANCIERA COMO  
SACAR UN PROVECHO  
DIRECTO DE LOS  
MISMOS**



importante de la población mundial actual. **Galeano y Peña** indican que el nombre de *big data* se refiere principalmente a estas nuevas masas de datos recogidos de forma automática que están ya cambiando el mundo en que vivimos y que engloban no solo los datos personales de millones de personas, sino los datos recogidos por sensores instalados para seguir el comportamiento de animales, el crecimiento de los cultivos, el funcionamiento de máquinas y procesos o la evolución de fenómenos meteorológicos o climáticos. Sugieren los autores que las entidades financieras pueden mejorar su situación diseñando mecanismos para recoger y analizar la enorme cantidad de información que genera la actividad económica de sus clientes y utilizarla para adaptar más sus políticas comerciales a las necesidades de sus clientes. Por ejemplo, el análisis detallado de distintas series de ingresos y gastos en la cuenta de cada cliente puede anticipar cambios que indican un aumento de su probabilidad de abandono. Por otro lado, esta información permitiría anticiparse a las necesidades de los clientes y proponerles estrategias para mejorar su comportamiento financiero. Además, esta información puede enriquecerse con otros datos disponibles sobre los clientes en las redes sociales y otros sistemas públicos de captación de datos, mejorando la segmentación de los clientes y permitiendo mejores predicciones sobre su actividad. Un uso inteligente de toda esta información puede aumentar la lealtad de los clientes con su institución, mejorar la imagen pública del banco y situarlo en una posición más sólida ante los retos futuros derivados de la entrada en el sector financiero de empresas líderes en la recogida y manejo de información.

**LA INFORMACIÓN  
DETALLADA SOBRE  
SUS CLIENTES PUEDE  
ADEMÁS REDUCIR  
SUS COSTES, AL  
DISMINUIR EL FRAUDE  
Y LA MOROSIDAD, Y  
CONducir A MEJORES  
PREDICCIONES**

Una de las conclusiones generales del artículo es que la información detallada sobre sus clientes puede además reducir sus costes, al disminuir el fraude y la morosidad, y conducir a mejores predicciones que disminuirán los costes asociados al riesgo. Por otro lado, los grandes bancos disponen al agregar la evolución de sus clientes, preservando la confidencialidad de los datos individuales, de una información muy valiosa para prever el ciclo económico y anticipar problemas en sectores concretos. La experiencia en otros muchos sectores económicos indica que esta información convenientemente utilizada puede generar valor económico para los bancos.

También se analiza el caso del *big data* en banca en el análisis de **Jesús Lozano, Tomasa Rodrigo y Jorge Sicilia**. Los autores ilustran el impacto que el uso de la ciencia de datos y la inteligencia artificial han tenido en la transformación del sistema financiero, de los procesos internos de las entidades en sus análisis y del servicio al cliente.

Señalan que la experiencia del cliente se ha convertido en la piedra angular de la actividad financiera y en una fuente de ventaja competitiva

para las entidades. Los consumidores están cada vez más informados y son más exigentes, demandando servicios personalizados de mayor calidad, lo que ha supuesto un cambio de paradigma para la banca, que debe adaptarse a un nuevo cliente, entendiendo mejor su situación y hábitos financieros, ayudándole a tomar mejores decisiones y ofreciendo soluciones personalizadas.

Sugieren **Lozano, Rodrigo y Sicilia** que en este contexto de cambio disruptivo será crucial afianzar los tres pilares básicos para la aplicación de las técnicas avanzadas de análisis de datos —la ética, la regulación y la gobernanza del dato—, que es el camino para contar con la confianza del cliente, mucho más consciente del valor de sus datos. De esta forma, la transparencia sobre el uso de la información, explicando por qué y para qué se utilizan sus datos se convertirá en un factor diferenciador entre las entidades bancarias.

En el artículo se muestra que los equilibrios que se formen en el futuro en el sector, y en particular la forma en que la innovación tendrá lugar en el sector financiero dependerá en gran medida del tipo de información al alcance de las empresas y muy especialmente del marco regulatorio. La regulación tendrá un rol fundamental para promover el marco de desarrollo de la competencia y el entorno de protección para el usuario y para el sistema financiero. Desde nuestro punto de vista, la intervención regulatoria se tiene que centrar en: (1) establecer un marco de responsabilidad claro que genere confianza en el uso de servicios basados en IA, (2) aumentar los datos disponibles mediante la cooperación público-privada para la compartición de datos anonimizados, (3) apoyar la innovación en datos por parte de las entidades financieras eliminando las barreras de acceso a infraestructuras ofrecidas por terceros para la gestión de datos, dando un tratamiento favorable a las inversiones en *software* y modificando o favoreciendo una interpretación más flexible del principio de minimización de datos recogido en la normativa de protección de datos, así como (4) fomentar la coordinación internacional para garantizar una postura armonizada sobre el uso de esta tecnología que cree un entorno competitivo equilibrado a nivel internacional.

El último análisis referido al *big data* en este bloque corresponde a **David Cano**. Indica que teniendo en cuenta la actual revolución tecnológica está claro que el sector financiero es uno de los más afectados y, dentro de él, la gestión de activos, en una doble vertiente: toma de decisiones y asesoramiento de clientes. En ambos casos, el *big data* debe ayudar a tomar mejores decisiones y también, aunque de forma menos disruptiva, a reducir costes. Por lo que respecta a la gestión de activos, el uso del *big data* es todavía reducido, tal vez por-

**LA TRANSPARENCIA  
SOBRE EL USO DE  
LA INFORMACIÓN,  
EXPLICANDO POR  
QUÉ Y PARA QUÉ SE  
UTILIZAN SUS DATOS  
SE CONVERTIRÁ  
EN UN FACTOR  
DIFERENCIADOR  
ENTRE LAS ENTIDADES  
BANCARIAS**

que el contraste de la eficacia de los modelos no es, por su horizonte temporal, lo suficientemente largo. Pero consideramos que a medida que se avance en su disponibilidad, se incorporará en los procesos de toma de decisiones. Por tanto, se considera el *big data* como una herramienta más que se usará de forma habitual, como ahora es común utilizar índices de sentimiento, algo inimaginable hace tres o cuatro décadas, por ejemplo. Y podrá ser un dinamizador de los modelos cuantitativos, que podrán mejorar sus algoritmos. Por último, el uso del *big data* no se limitará a los activos cotizados, sino que es posible que su uso se haga más frecuente en los no cotizados (*private equity* y *direct lending*), donde hay menos información.

**EL CLIENTE DEBE SER  
CONSCIENTE DE QUE  
SUCEDE COMO CON  
EL MÉDICO: CUANTO  
MÁS SE SEPA DE ÉL,  
MÁS EFICAZ SERÁ  
EL TRATAMIENTO  
RECOMENDADO**

Considera **Cano** que el *big data* se incorporará en el proceso de toma de decisiones, pero como una pieza más dentro del proceso, tanto en los gestores global macro como en los cuantitativos. Por suerte o por desgracia, señala el autor, tanto la economía como los mercados financieros sufrirán siempre cambios estructurales que harán imposible su perfecta modelización y predicción. Y porque, además, surgirán nuevos factores que impacten sobre las variables económicas y las cotizaciones y su incidencia no siempre será la misma. Respecto al grado de conocimiento del cliente, supondrá un claro avance, aunque siempre condicionado a que se cuente con su autorización. Con todo, el cliente debe ser consciente de que sucede como con el médico: cuanto más se sepa de él, más eficaz será el tratamiento recomendado por ajustarse en mayor medida a su situación particular.

## EXPERIENCIAS Y CASOS

En este último bloque se han reunido experiencias reales de la industria financiera y *tech* que ilustran algunos de los contenidos teóricos y empíricos de los apartados anteriores. A modo de análisis global, **Pedro J. Cuadros-Solas** analiza los principales avances en la transformación tecnológica del sistema bancario. Señala **Cuadros-Solas** que en un contexto cada vez más digital, la adopción e implementación de nuevas tecnologías en la industria bancaria es clave para mejorar la experiencia del cliente en la prestación de servicios financieros al tiempo que se refuerza la seguridad. De ahí que, en relación a otras industrias el sector bancario lidere el gasto tecnológico. La evidencia muestra que dicho proceso de cambio tecnológico en la industria bancaria es susceptible de acelerarse. Se espera una mayor relevancia del gasto tecnológico en los presupuestos de las entidades bancarias, de manera que las tasas de crecimiento de los próximos años superen a las actuales.

El autor examina la evolución del gasto tecnológico de las entidades bancarias, el grado de adopción de la llamada «nueva tecnología

bancaria» y el impacto de dicha tecnología en las entidades financieras. El análisis del gasto tecnológico evidencia que dicho proceso de transformación tecnológica de la industria bancaria es global, estando a su vez, sometido a una continuada aceleración. Además, una parte importante de dicho gasto tecnológico se concentra en las tecnologías integrantes de la «nueva tecnología bancaria». Actualmente las entidades bancarias emplean la «nueva tecnología bancaria» para fortalecer su posicionamiento competitivo, mejorar directamente la experiencia de sus clientes y mejorar su eficiencia operativa. Este esfuerzo tecnológico del sector se está produciendo tanto individualmente, donde cada entidad decide y ejecuta su presupuesto tecnológico de acuerdo con sus prioridades, como a través de proyectos globales, en los que participan un conjunto de entidades bancarias.

**Cuadros** evidencia la existencia de diferencias entre las entidades bancarias en función del grado en que han adoptado la nueva tecnología bancaria. Aunque no puede inferirse una relación de causalidad, sí parecen existir evidencias a favor de una cierta correlación positiva entre la adopción de las nuevas tecnologías, la rentabilidad bancaria y la capacidad de generar ingresos.

**Jesús Pérez** analiza uno de los aspectos más revolucionarios y prometedores para el sector bancario y financiero, la inteligencia artificial. Señala el autor que el sector financiero ha asistido durante estas últimas décadas a cambios tecnológicos que han tenido un impacto muy relevante en su eficiencia y en la forma de entender la distribución de productos financieros. El término *fintech* (*Finance & Technology*) ha emergido como un concepto que viene a describir cómo el sector se ha reinventado desde la base de la tecnología para concebir una nueva forma de entender cómo ofrecer servicios financieros. Según el autor, ante una perspectiva sobre la que existen importantes controversias en la actualidad, esto ha permitido profundizar en la digitalización de todos los procesos y la tendencia hacia un menor coste de los procesos transaccionales que históricamente requerían de un alto esfuerzo humano de cálculos y consolidaciones.

Según Pérez, el rápido desarrollo de la capacidad tecnológica ha permitido acelerar este proceso y la aparición de nuevos competidores. Señala que la velocidad de innovación es cada vez mayor y, sin haberse consolidado totalmente *fintech*, asistimos a la creación de un nuevo paradigma de innovación que en el sector de las finanzas puede conceptualizarse como finanzas descentralizadas (*DeFi: Decentralized Finance*) y que se construye sobre las bases de bitc  n y *blockchain*. Estamos en una fase muy incipiente de esta revoluci  n que supone un cambio disruptivo que viene a dar el relevo de la

disrupción al fenómeno *fintech* que ha entrado en una etapa de innovación incremental. Se trata de un nuevo fenómeno de disrupción que es totalmente diferente de disrupción que el definido por *fintech*.

Considera el autor que se trata de un nuevo paradigma y que, en la actualidad, los servicios financieros de finanzas descentralizadas (*DeFi*) han conseguido gestionar más de 600 millones de dólares, siendo uno de los crecimientos más importantes de aplicaciones financieras de las últimas décadas. En todo caso, afirma **Pérez**, la aplicación de *DeFi* a las finanzas encara importantes desafíos. En particular, su encaje en la regulación financiera, en la medida en que los registros descentralizados ofrecen, por naturaleza, mayores retos para su seguimiento y control. Es posible que en un futuro estas arquitecturas supongan una alternativa para un acceso a servicios financieros universales básicos y que vayan teniendo un mayor volumen. Es esta perspectiva, asimismo, la que genera inquietud adicional reguladora y supervisora, en la medida en que con una penetración elevada, las *DeFi* supongan un riesgo para la estabilidad global financiera.

La inteligencia artificial también es el objeto principal de la contribución de **Igor Alonso** y **Adrián Carrio**. Los autores parte de un ejemplo, la realidad de que un simple mensaje publicado en una red social, es capaz de arrastrar los mercados casi un 2 por 100 en cuestión de minutos. Señalan que, ante esta realidad, un inversor institucional no puede permitirse el lujo de no disponer de esta información de forma inmediata. Esta necesidad es la que está provocando en los mercados financieros el auge de técnicas de gestión cuantitativas basadas principalmente en tecnología, *big data* e inteligencia artificial.

Los autores recuerdan que, a la espera de una nueva era tecnológica con la llegada de la informática cuántica, los últimos años estamos siendo testigos de incrementos exponenciales de las capacidades computacionales y de almacenamiento, y de nuevas soluciones informáticas virtuales distribuidas, que han incrementado las posibilidades de la industria financiera, alcanzando cotas inimaginables hace años. Para los autores, la inteligencia artificial se ha vuelto clave en este punto, puesto que estas inmensas cantidades de información han de ser tratadas y posteriormente analizadas de forma automática, por lo que el desarrollo de sistemas basados en *Machine Learning* capaces de efectuar esta tarea al instante, se ha vuelto imprescindible. Del mismo modo, se hace necesaria la elaboración de sistemas automáticos de *trading* que de forma inmediata adopten decisiones de inversión, y aprovechen las oportunidades que el *big data* ofrece, y aquí, de nuevo, el *Machine Learning* juega un papel clave.

Como consecuencia, se llega a la conclusión, entre otras, de que la estrategia más extendida a nivel global en mercados financieros es la de *buy and hold*, es decir estrategias de inversión cuya finalidad es invertir y mantener la posición en los mercados, estrategias no muy activas en su operativa, más allá de rebalanceos o coberturas. Concluyen **Alonso y Carrio** que la inteligencia artificial se ha hecho un hueco en los mercados financieros como una herramienta imprescindible en la industria de inversión, por lo que su uso se generalizará con seguridad en los próximos años. Sin embargo, la inteligencia artificial difícilmente sustituirá al gestor humano totalmente, sino que, salvo casos puntuales de entidades muy especializadas, en general lo complementará en su toma de decisiones o se empleará como instrumento para crear estrategias colaterales a la inversión principal.

Se cierra este volumen de PAPELES DE ECONOMÍA ESPAÑOLA con una contribución muy ilustrativa de cómo las nuevas tecnologías cambian los canales de interacción entre oferta y demanda. En el artículo de **Iván Nabalón** señala que la gestión de la identidad electrónica es una pieza clave para entender el sector financiero del futuro. Entender, por tanto, sus circunstancias: (1) cómo la regulación impulsa las nuevas tecnologías de identificación, autenticación y contratación. (2) Las oportunidades que se generan para vender servicios cuya venta hasta la fecha solo ha sido posible en oficinas comerciales y (3) el impacto que tiene en el crecimiento del negocio en un contexto global y multicanal, puede ser imprescindible para todos los agentes que participan en el desarrollo del sector.

Considera **Nabalón** que la captación ubicua de clientes, los pagos con la cara, el cambio de la gestión del riesgo a un modelo más determinístico, el consumo por suscripción el uso común de las monedas virtuales, la retirada de dinero de un cajero con una sonrisa o la optimización de oficinas comerciales son solo algunos ejemplos de cómo las nuevas tecnologías de identificación electrónica están impactando en el sector financiero.

El autor explica cómo en Europa se lleva trabajando años en planificar y poner en valor la nueva regulación del sector financiero y cómo esta regulación está siendo extendida a otras regiones y países. Se describe la regulación en vigor: nueva directiva de prevención de blanqueo de capitales y financiación del terrorismo, de privacidad, pagos y banca abierta o servicios electrónicos de confianza y cuáles son las oportunidades que plantea para la aplicación de nuevas tecnologías y, por ende, para la generación de nuevos negocios.

**LA INTELIGENCIA ARTIFICIAL SE HA HECHO UN HUECO EN LOS MERCADOS FINANCIEROS COMO UNA HERRAMIENTA IMPRESCINDIBLE EN LA INDUSTRIA DE INVERSIÓN, POR LO QUE SU USO SE GENERALIZARÁ CON SEGURIDAD EN LOS PRÓXIMOS AÑOS**

**LA RETIRADA DE DINERO DE UN CAJERO CON UNA SONRISA O LA OPTIMIZACIÓN DE OFICINAS COMERCIALES SON SOLO ALGUNOS EJEMPLOS DE CÓMO LAS NUEVAS TECNOLOGÍAS DE IDENTIFICACIÓN ELECTRÓNICA ESTÁN IMPACTANDO EN EL SECTOR FINANCIERO**



Asimismo, el artículo ilustra el impacto que tendrán estas oportunidades que ya están aconteciendo en nuestro sector y otros sectores para ser global y multicanal. Ofrece, además, ejemplos ya en práctica en entidades financieras sobre la aplicación de tecnologías de identificación electrónica.

Las contribuciones de este número suponen una aproximación interdisciplinar (académica, regulatoria y de práctica financiera y tecnológica) a los cambios en el sector financiero inducidos por nuevas formas del tratamiento de la información. Se apunta a transformaciones que están sucediendo y que tienen ya una incidencia significativa y a otras que, a la vuelta de unos años, pueden haber completado una transformación de un sector como el financiero, en el que la información y la tecnología siempre han sido herramientas fundamentales, y ahora son un elemento estratégico de primer orden.

---

COLABORACIONES

**I.**  
**DISRUPCIONES, FACTORES DE  
COMPORTAMIENTO Y TECNOLOGÍA**

## Resumen

Este documento analiza la disrupción tecnológica en el sector bancario, su impacto sobre la competencia y su potencial para aumentar la eficiencia y el bienestar del cliente. Se abordan las posibles estrategias de los participantes-bancos tradicionales, firmas *fintech*, y el papel de la regulación. Aunque la competencia aumentará con los nuevos entrantes, el impacto a largo plazo dependerá de la regulación. El reto para los reguladores es mantener unas condiciones equitativas para los competidores y lograr un equilibrio entre el fomento de la innovación y la preservación de la estabilidad financiera, junto con la protección de los consumidores en el nuevo entorno.

**Palabras clave:** fintech, bigtech, estrategia bancaria, competencia, regulación, estabilidad financiera.

## Abstract

This paper surveys the technological disruption in banking examining its impact on competition and the potential to increase efficiency and customer welfare. It analyzes the possible strategies of the players involved, incumbents, *fintech* firms and the role of regulation. Competition will increase as new players enter the industry but the long run impact will depend on regulation. The challenge for regulators is to keep a level playing field striking a balance between fostering innovation and preserving financial stability. Consumer protection concerns raise to the forefront.

**Keywords:** FinTech, BigTech, bank strategy, competition, regulation, financial stability.

**JEL classification:** G21, G23, G28, L13, L17.

# LA BANCA FRENTE A LA DISRUPCIÓN DIGITAL

Xavier VIVES (\*)

IESE Business School

DESDE la crisis financiera de 2007-2009, el sector bancario se ha enfrentado a un entorno marcado por tipos de interés bajos, desapalancamiento y/o escaso crecimiento crediticio, incremento de los requisitos en materia regulatoria y de cumplimiento normativo, así como el daño a su reputación. Junto con la aparición de estas amenazas, este sector ha sufrido importantes cambios en los últimos años. Los bancos han tenido que lidiar con la disrupción digital provocada en el sector minorista por los nuevos competidores *fintech* (abreviatura de *financial technology*) y los basados en plataformas. Conviene recordar que la capitalización de las grandes empresas tecnológicas, como Amazon o Google, duplica con creces la de JP Morgan.

La actividad bancaria está pasando de girar en torno a las sucursales físicas a utilizar de manera intensiva la tecnología de la información y el *big data*, junto con recursos humanos altamente especializados. Los bancos afrontan una mayor competencia por parte de otros intermediarios –cada vez más digitales– en su negocio principal, como los servicios de pagos y asesoramiento. El auge del sector *fintech* ha provocado un cambio en el uso de la tecnología para desarrollar nuevos servicios y modelos de negocio, consistente en el empleo de información innovadora y tecnología de automatización en la esfera de los servicios financieros. La velocidad de adopción de las distintas novedades en

tecnología digital y de la adquisición de usuarios asociados a ellas se ha acelerado notablemente. De hecho, el principal cambio proviene ahora de la disrupción digital en el sector, que obliga a los operadores tradicionales con tecnologías heredadas potencialmente obsoletas (como el *mainframe*) y redes de sucursales sobredimensionadas a igualar los estándares de servicio que los nuevos competidores pueden ofrecer. Las expectativas de los clientes en materia de transparencia y facilidad de uso de la interfaz han cambiado. En Asia y África, los avances tecnológicos han permitido expandir los servicios de banca a segmentos de la población anteriormente no bancarizados. La disrupción digital marcará un punto de inflexión, ya que incrementará la competencia y el acceso a los mercados bancarios con un impacto potencialmente grande. La banca evolucionará hacia un modelo basado en plataformas centradas en el cliente, y las entidades tradicionales se verán obligadas a reestructurarse (1).

La disrupción digital ofrece un gran potencial para mejorar la eficiencia mediante la innovación, una oferta más diversificada y un sistema financiero más competitivo, lo que permitirá ampliar el mercado y, con ello, incrementar la inclusión financiera. Esta disrupción presionará los márgenes de los operadores tradicionales, lo que quizá les incite a asumir más riesgos, además de dar lugar a una carrera por capturar las rentabilidades del

sector. Para que el potencial de eficiencia se materialice, la reestructuración de las entidades tradicionales deberá producirse en paralelo a la entrada de nuevos competidores, sin que lleguen a consolidarse nuevas posiciones dominantes. Los nuevos participantes (*fintech* y en particular *bigtech* (2)) deberían ganar cuota de mercado gracias a las mejoras en eficiencia, y no por eludir la normativa o monopolizar la interfaz con los clientes. Asimismo, los reguladores deberán esforzarse por detectar las nuevas amenazas para la estabilidad financiera que las nuevas clases de riesgo sistémico generadas plantean.

La estructura del presente documento es la siguiente: en la sección primera se describe la disrupción tecnológica en el sector bancario/financiero. La segunda sección aborda la interacción entre los nuevos participantes y las entidades tradicionales. En la sección tercera se analizan los efectos de la reglamentación y las implicaciones para la estabilidad financiera. A continuación, se presentan las observaciones finales.

## I. DISRUPCIÓN TECNOLÓGICA Y EFICIENCIA

En esta sección examinamos los catalizadores de oferta y demanda de la disrupción digital y el impacto de la tecnología *fintech* sobre la eficiencia.

La disrupción digital en el sector financiero está impulsada por factores tanto en el lado de la oferta (principalmente, avances tecnológicos) como en el de la demanda (cambios en las expectativas de servicio de los consu-

midores), (véanse Carstens, 2018 y Financial Stability Board, 2019). Respecto al primero, algunos factores relevantes son las API de Internet (3), el *cloud computing*, los *smartphones* y el *blockchain* (tecnología de cadena de bloques).

Los dispositivos móviles se han convertido en un elemento fundamental de la vida diaria de los consumidores en muchos países, al expandir la disponibilidad de servicios financieros y convertirse en una plataforma para desarrolladores de terceros. En ellos se presenta la interfaz del cliente con múltiples funciones, incluidos pagos (monedero), transferencias de efectivo y compras *online*. La integración está muy avanzada en Asia, donde las *apps* de pago dan servicio actualmente a cerca de mil millones de usuarios y forman parte de un paquete de servicios con comercio electrónico, chat, envíos y pedidos de comida y vehículos con conductor (4). A pesar de que los bancos tradicionales, Visa y MasterCard, continúan liderando el mercado de las operaciones de pago, son otras empresas no bancarias, como PayPal, Apple o Google —y nuevos participantes como Revolut, N26 o Transferwise— las que suelen estar detrás de las innovaciones en materia de pagos. Por ejemplo, los sistemas de pago a través del móvil tienen un efecto considerable en aquellos países en los que el porcentaje de personas con cuenta corriente es reducido. Este suele ser el caso de los países africanos, en los que tan solo una cuarta parte de la población dispone de cuenta bancaria, pero un porcentaje muy superior posee un teléfono móvil (véase *The Economist*, 2015). Vale la pena señalar el salto tecnológico que disponer de servicios bancarios a

través del móvil representa para quienes no poseen una cuenta bancaria.

Otra posible vía de disrupción para los sistemas de pago tradicionales podría ser, en principio, las monedas digitales como el bitcóin. En los sistemas de criptomonedas, las técnicas de encriptación controlan la generación de unidades monetarias mediante el empleo de tecnología *blockchain* (véase Geneva Reports on the World Economy, 2018). Esta tecnología de registros distribuidos permite transferir sumas de dinero entre iguales (*peer-to-peer*) mediante transacciones autenticadas por muchos ordenadores (de usuarios de todo el mundo), todo ello sin necesidad de intermediario alguno. Sin embargo, las criptomonedas presentan limitaciones inherentes (como el tiempo y el coste asociados a la realización de transacciones y la incertidumbre normativa por su capacidad de contribuir a la actividad delictiva y el blanqueo de capitales) que las convierten más en una inversión especulativa que en una reserva de valor y/o un medio de transacción. Pese a ello, la tecnología *blockchain* podría potenciar los efectos disruptivos de los nuevos participantes, ya que las plataformas *fintech* posiblemente podrían explotar mejor las innovaciones con el potencial de ahorro de costes que esta tecnología ofrece. El impacto disruptivo se ve acentuado por el hecho de que los bancos tradicionales se han especializado en la intermediación financiera, y la tecnología *blockchain* podría reducir la necesidad de dicha intermediación. Potencialmente, la disrupción puede ser mucho mayor por la parte de las monedas digitales de los proveedores de dinero electrónico (de los

que el proyecto Libra asociado a Facebook es un ejemplo) (5).

A los factores tecnológicos antes mencionados hay que añadir consideraciones de índole regulatoria y de estructura de mercado –que abordaremos más adelante–, que podrían favorecer la disrupción, como la concentración en mercados de productos bancarios, la reducción de la competencia y la desigualdad en la regulación.

Los estímulos por el lado de la demanda están asociados a las mayores expectativas de servicio de los consumidores pertenecientes a la generación del móvil. El incremento de tales expectativas viene provocado por la digitalización del comercio y la capacidad de efectuar transacciones en tiempo real que brindan los dispositivos conectados a Internet. De este modo, empresas como Uber, Amazon y similares ofrecen una mayor comodidad, velocidad y facilidad de acceso a los servicios financieros. Las plataformas *fintech* han sabido aprovechar estas necesidades no atendidas de los clientes en la esfera de los pagos y transferencias (como el envío de remesas internacionales), el crédito y el asesoramiento de inversión. Los factores demográficos y el daño reputacional sufrido por los bancos tradicionales también juegan un papel importante en el caso de las generaciones jóvenes, más proclives a utilizar los productos *fintech* de los bancos digitales.

La revolución digital ha transformado la demanda de servicios financieros: el foco del sector está ahora en el consumidor, al que se ofrece una experiencia mejorada. Respecto del lado de la oferta, las entidades tradicionales se han quedado con tecnologías

| CUADRO N.º 1                                                           |                                                                                     |
|------------------------------------------------------------------------|-------------------------------------------------------------------------------------|
| VENTAJAS Y DESVENTAJAS DE LAS <i>FINTECH</i>                           |                                                                                     |
| VENTAJAS                                                               | DESVENTAJAS                                                                         |
| Tecnología superior sin sistemas heredados; operativa simplificada.    | Ausencia de una base de clientes instalada y fiel.                                  |
| Interfaz intuitiva y nuevo estándar de experiencia para el consumidor. | Acceso limitado a información blanda.                                               |
| Enfoque en segmentos de negocio/actividades con mayor ROE.             | Falta de reputación y reconocimiento de marca.                                      |
| Más financiación mediante recursos propios.                            | Elevado coste del capital y reducido tamaño de su balance.                          |
| Capaces de atraer al mejor talento.                                    | Falta de experiencia y pericia en gestión del riesgo y navegación de la regulación. |
|                                                                        | Sin acceso al prestamista de última instancia sin licencia bancaria.                |

Fuente: Vives (2019b).

obsoletas, como la excesiva dependencia de *mainframes* rígidos, así como con redes de sucursales sobredimensionadas, cuando las nuevas generaciones desean operar a través de sus teléfonos móviles. El sector cuenta con un exceso de capacidad y, lo que es aún peor, con un tipo de capacidad inadecuada. La industria está experimentando una profunda reestructuración en un contexto de bajos niveles de tipos de interés y rentabilidad (sobre todo, en la zona del euro y Japón).

El empleo de nuevas tecnologías presenta importantes implicaciones en materia de bienestar, ya que podría reducir los costes de intermediación financiera en los ámbitos de los préstamos, sistemas de pago, asesoramiento financiero y seguros, así como generar productos mejorados para los consumidores (véase Philippon, 2018 y Vives, 2017). Mediante su tecnología de originación de préstamos *online*, las *fintech* proporcionan un mayor grado de comodidad a sus prestatarios.

El Reino Unido, Estados Unidos, Singapur, Alemania,

Australia y Hong Kong son los principales centros de *fintech*, basados en el talento, el acceso a la financiación, las políticas gubernamentales y la demanda de esta clase de servicios (véase EY, 2016). A su vez, el impacto de las empresas de *fintech* ha sido más pronunciado en China, en donde los gigantes tecnológicos (Alibaba, Baidu y Tencent) ofrecen servicios financieros de forma activa.

Las plataformas *bigtech* cuentan con la mayoría de las ventajas de las *fintech*, pero sin prácticamente ninguno de sus inconvenientes (con excepción de las dos últimas desventajas del cuadro n.º 1). Así, disponen de una base de clientes establecida fiel, muchos datos de los clientes, una reputación elevada, una marca potente, pueden aprovecharse de los efectos de red, tienen capacidad de presión y pueden financiar sus actividades con un coste del capital reducido. Por ello, las *bigtech* presentan un potencial de disrupción muy superior para el negocio de la banca tradicional.

Está previsto que el impacto de ambos tipos de entidades no

bancarias sea significativo en las soluciones de pago y la prestación de servicios de asesoramiento en mercados de capitales, así como en lo referente a la reconfiguración de las expectativas de los consumidores. En otros segmentos de la banca minorista, especialmente en originación y distribución de créditos al consumo y a las pymes, el efecto está menos claro. La tecnología digital genera transformaciones en tramitación general (*back office*), gestión de clientes y análisis de datos.

No hay duda de que la tecnología *fintech* aumentará el acceso a los mercados bancarios, así como la competencia en el corto plazo. La cuestión es si la entrada de las plataformas *bigtech* consolidará a los grandes *players* con posiciones dominantes y si eso podría plantear problemas de riesgos sistémicos.

## II. NUEVOS PARTICIPANTES Y OPERADORES TRADICIONALES

Los competidores *fintech* están invadiendo el negocio tradicional de los bancos, a pesar de los esfuerzos de estos por adaptarse al mundo digital. Por el lado de la oferta, los nuevos competidores pueden utilizar información dura (codificable) para erosionar la relación existente entre banco y cliente, que se basa habitualmente en información blanda (derivada del conocimiento obtenido a partir de la relación banco-cliente). Es decir, los nuevos participantes con capacidades tecnológicas pueden tratar grandes cantidades de datos de los consumidores (por ejemplo, mediante técnicas de aprendizaje automático) y utilizarlos, mientras

que las entidades tradicionales venían utilizando estos datos, en el mejor de los casos, mediante el contacto personal y la interpretación. No obstante, hasta el momento, son muchos los competidores de nuevo cuño que se están absteniendo de solicitar una licencia bancaria para evitar los costes de *compliance* mientras intentan arañar negocios lucrativos a los bancos. Los nuevos participantes intentan beneficiarse del arbitraje regulatorio. Por el lado de la demanda, intentan sacar provecho a la desconfianza que los *millennials* sienten hacia los bancos, ofreciendo servicios digitales con los que las generaciones más jóvenes se sienten cómodas (véase, por ejemplo, Foro Económico Mundial, 2017).

Aunque los bancos se han centrado históricamente en el producto, los nuevos participantes ponen el énfasis en el cliente, presionando así el modelo de negocio tradicional de aquellos. Los nuevos participantes tienen que concentrarse en el cliente porque eso es lo que constituye la esencia de su negocio, mientras que los operadores tradicionales pertenecen a una práctica en la que el cliente ya había sido captado por el banco y se le vendían productos. De hecho, una ventaja competitiva de los bancos minoristas, que podría verse mermada por los nuevos participantes, es que disfrutaban de un acceso privilegiado a una base de clientes estable entre la que puede comercializar una amplia variedad de productos. Aunque la existencia de seguros de depósito podría facilitar la irrupción de nuevos competidores, como los bancos digitales, en este caso los participantes tendrán que soportar los costes asociados al cumplimiento normativo de los bancos, lo que, unido a las

licencias bancarias, impone una pesada carga para las pequeñas entidades.

En conclusión, la llegada de nuevos competidores al negocio de la intermediación dependerá, en gran medida, de la forma en que se apliquen la normativa y las garantías gubernamentales. El Reino Unido ha desarrollado un marco para facilitar la entrada de *fintech* y «neobancos» exclusivamente móviles, como Monzo, Revolut o Starling (con un regulador único, la Autoridad de Conducta Financiera, ACF, un *sandbox* (6) y *open banking*), mientras que en Estados Unidos existen muchas más barreras (fragmentación entre las entidades reguladoras y normativas que obligan a contar presencia física mediante sucursales). Además, la estricta regulación bancaria (como, por ejemplo, una exigente normativa de capital) está trasladando la actividad al sector de los bancos en la sombra, y una proporción cada vez mayor de las entidades no bancarias son digitales.

Una cuestión crucial es si la aparición de los nuevos competidores no bancarios intensificará la competencia en la banca minorista y, de ser así, en qué medida lo hará. Para responder a la pregunta hay que ver que estrategias desarrollaran los distintos participantes en el mercado.

### 1. Estrategias de los bancos tradicionales y *fintechs*

Los operadores tradicionales podrían adoptar una estrategia de discriminación, en el sentido de que podrían aceptar la entrada de sus competidores en determinados segmentos de mercado e intentar que no se



produzca en otros. Cuando existen elevados costes de cambio de proveedor para los clientes, los bancos tradicionales se comportan como un «perro pachón» tranquilo con el fin de proteger la rentabilidad de su amplia base de clientes. Esto permitiría que un nuevo participante entrase y captase, por ejemplo, a clientes duchos en tecnología, o incluso a los no bancarizados. Los bancos podrían optar por aceptar su entrada, dado que reciben comisiones de intercambio de los nuevos operadores de servicio y porque podrían compensar con creces el recorte en los ingresos bancarios derivado de cada compra con el incremento de las operaciones totales realizadas por los clientes.

Ocasionalmente, los nuevos participantes podrían optar por mantener un tamaño reducido, para no provocar una respuesta agresiva por parte de los operadores tradicionales. Por ejemplo, los préstamos P2P son una vía de entrada a pequeña escala cuando se dirigen principalmente a segmentos no bancarizados de la población. También pueden establecerse colaboraciones entre nuevos participantes y bancos tradicionales; de este modo, estos se beneficiarían del conocimiento informático y el arbitraje regulatorio –normativa menos estricta– que aportan aquellos, así como de su capacidad para captar nuevos clientes. Al mismo tiempo, las *fintech* podrían beneficiarse de la marca establecida, las economías de escala y los canales de distribución de los operadores tradicionales. Sin embargo, el escenario de entrada de nuevos bancos (con licencia) es menos probable, habida cuenta de los elevados costes de *compliance* asociados (7). Evidentemente, los bancos esta-

| CUADRO N.º 2                                                                                                                                                                                                                                                                                                                                                                                                                                       |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                           |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| ESTRATEGIAS: OPERADORES TRADICIONALES Y LAS <i>FINTECH</i>                                                                                                                                                                                                                                                                                                                                                                                         |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                           |
| BANCOS TRADICIONALES<br>(DISCRIMINAR POR SEGMENTOS)                                                                                                                                                                                                                                                                                                                                                                                                | <i>FINTECHS</i>                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                           |
| <p>Aceptación («perro pachón»)</p> <ul style="list-style-type: none"> <li>• Cuando existen elevados costes de cambio.</li> <li>• Para recibir comisiones de intercambio de los nuevos operadores de servicio.</li> </ul> <p>Luchar, impedir la entrada («jefe de la manada»).</p> <ul style="list-style-type: none"> <li>• Cerrar/restringir el acceso a la infraestructura.</li> </ul> <p>Lanzar sus propios bancos totalmente <i>online</i>.</p> | <p>Centrarse en mantener un tamaño reducido («estrategia del cachorro»).</p> <ul style="list-style-type: none"> <li>• Sin licencia bancaria.</li> <li>• Por ejemplo, con los préstamos P2P dirigidos a segmentos no bancarizados de la población.</li> </ul> <p>→ Establecer asociaciones.</p> <p>Entrada en forma de banco digital (con licencia).</p> <ul style="list-style-type: none"> <li>• Menos probable por los elevados costes de <i>compliance</i> asociados.</li> </ul> <p>→ Consolidación o venta a bancos tradicionales.</p> |
| Fuente: Vives (2019b).                                                                                                                                                                                                                                                                                                                                                                                                                             |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                           |

blecidos también podrían lanzar sus propias entidades totalmente *online* (8).

A continuación, se muestra, en el cuadro n.º 2, una comparativa entre las estrategias posibles de los operadores tradicionales y las *fintech*.

## 2. Estrategias de los bancos tradicionales y plataformas *bigtech*

El negocio principal de las plataformas *bigtech* es la tecnología y los datos y, al contrario que las pequeñas *fintech*, también disponen de economías de escala significativas, grandes bases de clientes instaladas, marcas y reputaciones consolidadas, un gran volumen de beneficios no distribuidos y un acceso sin restricciones a los mercados de capitales. Así, pueden competir cara a cara con los bancos tradicionales, ya sea transformándose en bancos (intermediarios) y explotando las economías de alcance, mediante paquetes que

combinen su oferta actual con productos bancarios tradicionales, o bien como plataformas multilaterales (mercados) centradas en las actividades bancarias más rentables (véase Foro Económico Mundial, 2017 y De la Mano y Padilla, 2019).

Las *bigtech* pueden convertirse en bancos y aprovechar su valiosa información sobre las preferencias, hábitos y comportamientos de los consumidores, además de poder controlar las experiencias de compra de muchos de ellos y, desde hace poco, la distribución y comercialización de muchos proveedores. No solo cuentan con gran cantidad de datos de mayor calidad, sino que también disponen de una ventaja respecto a las herramientas (por ejemplo, algoritmos de inteligencia artificial [IA]) con las que los analizan para comprender las necesidades de los clientes e influir en ellos. Las *bigtech* también podrían ofrecer nuevos servicios mediante paquetes de sus servicios actuales (como el comercio electrónico y la pu-

bilidad *online*) con productos de banca tradicionales. La concesión de pequeños préstamos sería un primer paso para las grandes plataformas de comercio electrónico (como Ant Financial y JD.com, en China) que poseen ingentes cantidades de datos precisos sobre los hábitos de gasto de sus clientes. Junto con sus sólidas posiciones financieras y el acceso a capital de bajo coste, las empresas de *bigtech* podrían alcanzar rápidamente la escala y el alcance en los servicios financieros, sobre todo en segmentos de mercado en los que existen efectos de red, como pagos y liquidaciones, préstamos y seguros. No obstante, las plataformas *bigtech* podrían optar por no aceptar depósitos, ya que esto limitaría su capacidad de innovación, al quedar sujetas a las mismas obligaciones reglamentarias que los bancos tradicionales.

En cambio, al actuar como mercados, las plataformas permitirán negociar con distintas entidades financieras. Es posible que las plataformas de productos financieros se conviertan en el modelo de distribución principal. En su calidad de plataformas multilaterales, las *bigtech* pueden dirigirse a los segmentos de negocio más rentables de los operadores tradicionales.

Las *bigtech* pueden desplegar una estrategia de «plataforma envolvente» para excluir a otros intermediarios mediante su superioridad en materia de datos (ya que cuentan con fuentes de datos complementarias sobre clientes procedentes de otras líneas de negocio). Esta estrategia es una variante de la «adoptar y ampliar» utilizada inicialmente por Microsoft para controlar el sector de los navegadores de

Internet, que consistía en ofrecer todo lo que tu rival (Nestcape) ofrece más otras cosas. Téngase en cuenta que los consumidores son más propensos a recurrir a la plataforma que utilizan, como, por ejemplo, Android o iOS, para cubrir muchas de sus necesidades bancarias. Esto significa que la plataforma ejercerá de guardabarrera para una parte de los clientes y que los bancos deberán estar presentes en los distintos ecosistemas/plataformas competidores. Asimismo, las plataformas *bigtech* podrían subvencionar de forma cruzada productos tanto financieros como no financieros y obtener una ventaja competitiva.

La fuente de poder de mercado de las plataformas *bigtech* es un bucle de retroalimentación que genera ingentes cantidades de datos de clientes a través de la actividad de la plataforma, el tratamiento de los datos con técnicas de IA y aprendizaje automático, y la explotación de las externalidades de red, lo que, a su vez, genera más actividad y

datos (con economías de escala dinámicas, ya que, a mayor cantidad de datos, mejores serán los algoritmos y mayor será la capacidad de predicción). De esta forma, se consolida un ecosistema en el que los clientes soportan costes endógenos a la hora de cambiar de plataforma.

En el cuadro n.º 3 se recoge una comparativa entre las estrategias que emplean los operadores tradicionales y las *bigtech*.

A través de la tecnología y sus amplias bases de clientes, las *bigtech* podrían monopolizar la interfaz con los clientes, controlando la originación de préstamos y el negocio de distribución, mientras que los bancos tradicionales aceptarían depósitos e invertirían en productos distribuidos por las *bigtech* (9). Las empresas *bigtech*, cuando tienen una posición dominante, han discriminado con éxito a favor de sus propias filiales ascendentes o descendentes en sus plataformas centrales (tal como afirma la Comunidad Europea en

CUADRO N.º 3

ESTRATEGIAS: OPERADORES TRADICIONALES Y *BIGTECH*

| BANCOS TRADICIONALES                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                    | BIGTECHS                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                          |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Aceptación <ul style="list-style-type: none"> <li>Cooperación mediante asociaciones.</li> <li>Oferta de productos y servicios de banca exclusivos y especializados.</li> </ul> Luchan/compiten cara a cara convirtiéndose en plataformas/mercados. <ul style="list-style-type: none"> <li>Disfrutan de una mayor confianza (?) por parte de los clientes y de una seguridad de datos reforzada.</li> <li>Cuenta con una mayor capacidad de maniobra normativa y poder de presión similar al de las <i>bigtech</i>.</li> <li>No pueden igualar la estrategia de paquetes/subvenciones cruzadas de las <i>bigtech</i> con productos financieros y no financieros complementarios (pese a disfrutar de algunos efectos de red).</li> </ul> | Aceptación <ul style="list-style-type: none"> <li>Asociaciones.</li> </ul> Competencia cara a cara. <ul style="list-style-type: none"> <li>Se convierten en bancos/intermediarios mediante paquetes con sus ofertas y explotando economías de alcance.               <ul style="list-style-type: none"> <li>Optan por no aceptar depósitos para evitar la normativa.</li> </ul> </li> <li>Plataforma multilateral (mercado).               <ul style="list-style-type: none"> <li>Plataforma envolvente.</li> <li>Guardabarrera: monopolizan la interfaz con los clientes.</li> </ul> </li> </ul> |

Fuente: Vives (2019b).

tres casos antimonopolio abiertos contra Google en la Unión Europea [UE] por abuso de su posición dominante en las búsquedas, para favorecer su propio negocio vertical en un caso y, en otro, intentar proteger el dominio de su motor de búsqueda valiéndose de su posición dominante en sistemas operativos con Android).

Por tanto, aunque es probable que las firmas *bigtech* den lugar a una mayor competencia, este efecto podría revertirse a largo plazo si llegan a dominar la interfaz con el cliente. La historia nos ha mostrado que, cuando las *bigtech* se introducen en sectores con largas cadenas de valor vertical, pueden monopolizar los segmentos en los que operan mediante sus ventajas competitivas para, a continuación, expandir su poder de monopolio a otras ramas de negocio mediante los efectos de red.

Respecto a las estrategias que pueden adoptar los operadores tradicionales, existen un par de posibilidades. No obstante, imitar la estrategia de venta por paquetes de las *bigtech* no es una de ellas, ya que resulta muy difícil disputar sus posiciones dominantes en productos y servicios no financieros que pueden ofrecerse en paquetes con productos y servicios bancarios. La estrategia alternativa es cooperar con otros terceros. Los bancos tendrían que transformar su negocio de propiedad exclusiva en plataformas abiertas, compartidas con otros intermediarios financieros, para beneficiarse de las inversiones realizadas por todos los participantes en la plataforma. A su vez, podrían optar por competir frente a frente con las *bigtech* (dado que disfrutaban de algunos efectos de red) o cooperar me-

dianamente asociaciones. En este último caso, la cuestión de quién controlará la interfaz con los clientes resulta fundamental: si lo hacen las *bigtech*, entonces los bancos sufrirán una merma de sus márgenes de beneficio por la mercantilización de su negocio, por lo que podrían optar por especializarse en grupos de clientes específicos. También podrían constituirse asociaciones, como han hecho Amazon y JP Chase, o como recientemente han anunciado Apple y Goldman Sachs para ofrecer tarjetas de crédito, o Amazon y Bank of America para conceder préstamos.

En cualquier caso, los operadores tradicionales tendrán que reestructurarse, y su actual exceso de capacidad, unido a la necesidad de realizar grandes inversiones en tecnología de la información en un entorno de baja rentabilidad, desembocará en una consolidación. Estos operadores podrían beneficiarse de una mayor seguridad de los datos y de una mejor capacidad para maniobrar a través de la maraña normativa.

### III. REGULACIÓN Y ESTABILIDAD FINANCIERA

#### 1. Regulación

¿Cuáles son las consecuencias regulatorias de la disrupción digital? ¿De qué forma deberían regularse las firmas *fintech*? Es evidente que la normativa influirá en el tipo de competencia que se establezca entre operadores tradicionales y nuevos participantes. Una de las cuestiones fundamentales es si la regulación debería tener como objetivo crear unas condiciones equitativas (*level playing field*) o

si debería favorecer a los nuevos participantes para fomentar la competencia.

A pesar de que la mayoría de los marcos de supervisión actuales son anteriores a la aparición de las *fintech*, existen varios ejemplos de iniciativas normativas posteriores a la crisis financiera que merece la pena mencionar (véase Financial Stability Board, 2019). La Directiva de Servicios de Pago revisada (PSD2) de la UE es una normativa dirigida a potenciar la competencia concediendo acceso abierto a determinados tipos de datos bancarios de clientes a proveedores sin licencia bancaria de servicios de iniciación de pagos (SIP) y servicios de información de cuentas (SIC) (10). La iniciativa busca hacer más seguro y cómodo el uso de servicios de pago por Internet, proteger a los clientes de fraudes, abusos y problemas relativos a los pagos y, al mismo tiempo, fomentar los servicios de pago por telefonía móvil innovadores. Por ejemplo, la PSD2 estipula que los clientes puedan utilizar una *app* para ver una relación de todas sus cuentas, incluso las abiertas en otros bancos. Se está trabajando en otras iniciativas regulatorias en Japón, Canadá y México, entre otros grandes países.

Todas estas iniciativas regulatorias influirán en el tipo de competencia existente entre los operadores tradicionales y los nuevos. Si la regulación consigue garantizar unas condiciones equitativas, entonces aumenta la probabilidad de que se produzca una competencia cara a cara. Por otra parte, las políticas que implican una normativa asimétrica entre las empresas *fintech* y los bancos tradicionales pueden fomentar la entrada,

incentivar el acceso mediante unos costes de cambio de proveedor inferiores y potenciar la transparencia del mercado. Con todo, este aumento de la competencia a corto plazo debe equilibrarse, por cuanto existe un riesgo potencial a largo plazo de monopolización por parte de las *bigtech*. La Directiva PSD2 antes citada obliga a los bancos a brindar acceso a proveedores terceros (*TPP*, por sus siglas en inglés) autorizados a los datos de clientes; en particular, los bancos están obligados a proporcionar los datos de clientes a competidores autorizados de forma gratuita. Se ha desarrollado un sistema similar en el marco de la iniciativa de *open banking* del Reino Unido. Por otra parte, en virtud del Reglamento General de Protección de Datos (RGPD), los *TPP* –incluidas las plataformas *bigtech*– deberán facilitar la portabilidad de los datos únicamente en aquellos casos en los que resulte técnicamente viable. Todo esto podría colocar a los bancos en una situación desfavorable respecto a las plataformas *bigtech*, que se benefician del acceso no recíproco a datos valiosos (11). Las autoridades reguladoras deberán resolver la cuestión de quién deberá soportar la carga de los riesgos operacionales y de seguridad, así como del cumplimiento normativo, en especial cuando exista cooperación entre los operadores tradicionales y los nuevos.

Las principales recomendaciones de la Autoridad Bancaria Europea (ABE) sobre normativa de las *fintech* extraídas de una consulta general es aplicar un enfoque paneuropeo para garantizar un trato equitativo, así como para permitir el desarrollo de un gran mercado nacional de

las *fintech* que consiga escala y pueda competir a nivel internacional. En la consulta a la ABE, se apuntaba que más de un 30 por 100 de las *fintech* carecía de regulación y los operadores tradicionales se inclinan por que las entidades financieras que ofrezcan la misma clase de servicios y estén expuestas a los mismos riesgos queden sujetas a los mismos requisitos de regulación y supervisión.

La disyuntiva se encuentra entre, de una parte, ampliar el perímetro de la normativa bancaria a todos los proveedores de servicios financieros y, de este modo, limitar la innovación financiera (y, de forma implícita, extender una cobertura de protección estatal a los nuevos participantes) y, de otra, mantener a los nuevos participantes totalmente fuera del perímetro e inclinar las condiciones a su favor. Es preciso encontrar un equilibrio en el que el perímetro reglamentario abarque todas las actividades con riesgo sistémico potencial, al tiempo que se contemple algo más de flexibilidad para las que no planteen dicho riesgo. Cabe también señalar que son las entidades, y no las actividades, las que fracasan y pueden generar riesgos sistémicos. El centro del perímetro regulador debería ser las instituciones que ofrecen la prestación conjunta de depósitos y préstamos, esto es, las actividades bancarias básicas.

Hasta la fecha, la tendencia es regular los nuevos servicios de *fintech* mediante un *sandbox* normativo con el que las empresas pueden experimentar sin la carga regulatoria que la banca tradicional soporta. Esto también ofrece a los reguladores la oportunidad de buscar formas

más eficaces de salvaguardar la estabilidad, al tiempo que se fomenta la innovación. La experiencia pionera del Reino Unido ha sido valorada positivamente tanto por la ACF como por las empresas, entre otras cosas, porque ha demostrado que el regulador puede jugar un papel en el fomento de la innovación (véase Deloitte, 2018).

La protección de los consumidores reviste una enorme importancia en un entorno bancario abierto, ya que debe garantizarse a estos la integridad del proceso, y para ello es necesario que sus transacciones sean rastreables, de forma que pueda determinarse la responsabilidad cuando se produzca cualquier infracción. Por ello, es preciso proteger o mejorar el bienestar de los consumidores permitiendo que dispongan de un mayor abanico de proveedores entre los que elegir, de una mayor accesibilidad y calidad, y del respeto a la privacidad de sus datos, al tiempo que se reducen los riesgos de confusión y ciberataques (12).

Además de suscitar todas estas cuestiones, las tecnologías digitales también pueden proporcionar respuestas a las autoridades reguladoras, mejorar tanto la regulación como la supervisión, y ayudar tanto a los reguladores como a las empresas a reducir sus costes de *compliance*. La nueva tecnología puede utilizarse para lograr un cumplimiento más eficiente de los requisitos reglamentarios. Este enfoque se conoce como *RegTech*, que el Institute of International Finance define como «el empleo de nuevas tecnologías para atender los requisitos de cumplimiento normativo de forma más eficaz y eficiente».



## 2. Estabilidad financiera

La entrada de las empresas *fintech* en el sector bancario ha hecho surgir distintas fuentes de riesgo. Uno de sus principales efectos es que, en la medida en que esta entrada reduce la rentabilidad de los operadores tradicionales, estos podrían comenzar a asumir riesgos excesivos en un intento por compensar la presión a la baja sobre sus beneficios. De hecho, la respuesta de los reguladores ante el aumento del acceso al mercado y la mayor asunción de riesgos podría consistir en endurecer los requisitos prudenciales de los bancos, lo que a su vez podría incrementar los incentivos para saltarse la normativa y propiciar el crecimiento de la banca en la sombra. De este modo, asistiríamos a un repunte autoalimentado en la actividad de la banca en la sombra fuera del perímetro reglamentario. Por ejemplo, la regulación macroprudencial intenta limitar el riesgo sistémico, pero los límites impuestos a los bancos en materia de préstamos apalancados podrían incrementar los préstamos apalancados no bancarios. Esto es exactamente lo que sucedió con las directrices sobre apalancamiento ofrecidas en Estados Unidos por el Consejo de Estabilidad Financiera (Financial Stability Oversight Council), (véase Kim, Plosser y Santos, 2017).

Otras fuentes de riesgo asociadas a los nuevos participantes son las implicaciones de la disrupción digital en las asimetrías de información y su posible impacto sobre el riesgo sistémico.

Respecto a la primera cuestión, las plataformas tienen un impacto potencialmente ambiguo sobre el riesgo moral y los

problemas de selección adversa y, en consecuencia, sobre la estabilidad financiera. En la medida en que las plataformas poseen un reducido interés en los préstamos que ayudan a originar pero no a mantener, podrían plantearse problemas de riesgo moral. Dado que las plataformas asumen un papel clave principalmente en el proceso de filtrado de préstamos y, por lo tanto, se preocupan principalmente por maximizar el volumen de estos y los ingresos por comisiones, podrían optar por dejar que la calidad de los préstamos se reduzca. Este efecto podría verse agravado por su escasez de información blanda, aspecto en el que los operadores tradicionales las aventajan (véase Vallée y Zeng, 2019). El riesgo moral también podría aumentar incluso si las plataformas financian los préstamos que originan (como pueden hacer las *bigtech*), ya que tendrán incentivos para expandir el crédito con el fin de fortalecer los demás negocios de su plataforma, esto es, para vender productos o servicios adicionales en sus plataformas de comercio electrónico o para adquirir datos complementarios que monetizar a través de sus plataformas publicitarias.

Respecto de los impactos potenciales sobre el riesgo sistémico, son varias las fuentes de preocupación:

i) La primera es el peligro de que se desarrolle un sistema de pagos paralelo sin la supervisión adecuada de los bancos centrales, lo que podría suceder si las *bigtech* depositan fondos de los clientes directamente en los bancos, como sucede en China.

ii) La segunda inquietud se deriva de la posibilidad de que

una parte de las entidades financieras dependieran de una empresa *bigtech* (o de una pocas) que ofrezca servicios de terceros (como, por ejemplo, almacenamiento, transmisión o análisis de datos), algunos de ellos en la nube. En este caso, un ciberataque o fallo operativo podría plantear un riesgo sistémico.

iii) El propio desarrollo de grandes fondos *online* del mercado monetario (FMM), como el Yu'e Bao en China, que en principio no están asegurados, los hace vulnerables a episodios de pánico bancario (algo que, como descubrimos durante la crisis financiera de 2007-2009 en Estados Unidos, no cabe descartar). Por el lado positivo, las *startups fintech* podrían lograr operar con un apalancamiento inferior al de los bancos tradicionales (véase Philippon, 2018).

iv) Por último, si las *bigtech* entraran en los negocios bancarios principales, los temores sistémicos se incrementarían, ya que los problemas en los negocios no bancarios de estas empresas podrían contagiar a los bancos, que muy probablemente serían de importancia sistémica. Los principios prudenciales que propugnan la separación de la banca del comercio y la industria se aplican en este caso.

Los reguladores deberán aceptar un entorno complejo en el que los bancos tradicionales compiten con *fintech* ágiles y *bigtech* establecidas, y en el que podrían surgir nuevas formas de riesgo sistémico. Dado que la detección temprana es un factor clave para la prevención, las nuevas tecnologías deberían desarrollar herramientas de supervisión continua que saquen partido a sus grandes bases de

datos y sirvan como indicadores tempranos del riesgo. Estas herramientas deberían añadirse a las medidas de desarrollo de datos de riesgo sistémico del mercado y a la estructura en red de los vínculos existentes entre los intermediarios financieros (véase la sección 3.1.2 en Vives, 2016).

#### IV. RESUMEN Y CONCLUSIONES

La disrupción digital en la banca promete un incremento generalizado en la eficiencia y los servicios, ya que contribuye a superar las asimetrías de información (mediante el *big data* y las técnicas de IA), ofrece una intuitiva interfaz al consumidor y un mayor estándar de servicio, y conduce a la sustitución de tecnología obsoleta. La banca avanzará hacia un modelo centrado en el cliente. Todo esto plantea desafíos formidables para los operadores tradicionales, ya que se verán obligados a actualizar sus plataformas tecnológicas (pasando de *mainframes* relativamente rígidos a una nube más flexible) y a reducir su exceso de capacidad en sucursales en el actual entorno de baja rentabilidad (especialmente, en Europa y Japón), y además tendrán que intentar ofrecer el nuevo estándar de servicio en competencia con nuevos participantes que están invadiendo sus segmentos de negocio más rentables. Deberán llevar a cabo una profunda reestructuración y se producirá la consolidación. Los operadores tradicionales soportan intensos controles y obligaciones de cumplimiento normativo, y deberán superar el tremendo daño reputacional sufrido a causa de la crisis financiera de 2007-2009. Afrontan un dilema de si compe-

tir cara a cara o cooperar con los nuevos participantes. En el caso de las *fintech*, este dilema se resuelve mediante su adquisición o estableciendo asociaciones con ellas.

En el caso de las *bigtech*, los operadores tradicionales afrontan una situación potencialmente más delicada. La principal amenaza para ellos es que las *bigtech* intenten controlar la interfaz con los clientes mediante su superioridad en base de clientes (datos) gracias a su papel de guardabarreras en la distribución de productos financieros. Si esto llegara a suceder, los bancos tradicionales quedarían relegados a proveedores de productos en plataformas que no controlan, esto es, se produciría una mercantilización de su negocio. Algunos bancos, conscientes de esta amenaza, ofrecen plataformas abiertas que pueden incorporar productos de otros proveedores financieros, o han establecido asociaciones con *bigtechs*. En cualquier caso, los operadores tradicionales cuentan con algunas fortalezas que pueden aprovechar, como la confianza de los clientes para mantener a salvo sus datos, así como su conocimiento acumulado sobre la gestión de la complejidad y los marcos regulatorios restrictivos. Los operadores tradicionales que consigan prosperar serán los que logren pasar del *mainframe* a la nube, tengan pocas sucursales y mucho capital humano, y o bien se conviertan en plataformas digitales para mantener la interfaz con el cliente, o bien cuenten con productos exclusivos en las plataformas de distribución a los clientes.

Las firmas *bigtech* entrarán en los servicios financieros debido a la complementariedad de estos

con los datos de clientes que poseen y los productos que ofrecen, como muestra el ejemplo de China. El grado en el que lo hagan dependerá en gran medida del tratamiento regulatorio que reciban. De hecho, cabe que los reguladores prudenciales no les permitan adquirir una licencia bancaria completa debido a la posible contaminación entre sus actividades bancarias y no bancarias, que generaría riesgos sistémicos. En términos generales, la mayoría de los nuevos participantes se muestran reacios a solicitar una licencia bancaria por los costes de *compliance* que ello implica. Los bancos tienen acceso a una financiación más asequible, ya que pueden aceptar depósitos bajo la cobertura de programas de seguro público, si bien son objeto de intensos controles.

No hay duda de que el impacto inmediato de la disrupción digital será una erosión de los márgenes de los operadores tradicionales y un aumento del acceso a los mercados bancarios. El impacto a largo plazo dependerá de la estructura de mercado que acabe imponiéndose. La banca podría pasar del oligopolio tradicional a una nueva estructura con un número reducido de plataformas dominantes que controlan el acceso a una base de clientes fragmentada si unas pocas *bigtech*, en colaboración con algunos operadores tradicionales transformados en plataformas, consiguieran monopolizar la interfaz con los clientes y hacerse con las rentabilidades en el sector. Un factor clave para mantener un mercado suficientemente competitivo será que las personas dispongan de la propiedad y de la portabilidad de los datos, y que exista interoperabilidad entre plataformas, de



modo que los costes de cambio de proveedor para los clientes sean asequibles.

En la medida en que las ventajas en términos de eficiencia –información mejorada, tecnologías de filtrado, operativa simplificada y menor apalancamiento– sean los principales motores de la entrada de las *bigtech*, se producirá un aumento de la eficiencia y de la inclusión financiera en el sector financiero. Este efecto será especialmente pronunciado si, en respuesta a su entrada, los operadores tradicionales mejoran su eficiencia mediante reestructuraciones y la adopción de tecnologías más avanzadas. No obstante, si las fuerzas que impulsan la entrada de las *bigtech* giraran en torno al poder de mercado, el aprovechamiento de lagunas regulatorias y los efectos de arrastre de externalidades de red con fines de exclusión, entonces la eficiencia del sistema bancario podría resultar mermada en el largo plazo.

La disrupción digital también supone un desafío formidable para los organismos reguladores. Deberán adaptarse al mundo digital facilitando la competencia y permitiendo que los beneficios de la innovación calen en el sistema, al tiempo que protegen la estabilidad financiera. Para ello, estos organismos deberán coordinar la regulación prudencial y la política de competencia, para que el cumplimiento normativo no se convierta en una barrera de entrada y la propia entrada no devenga un factor desestabilizador. La escasa regulación de los nuevos participantes en la industria podría fomentar la competencia, pero esto también podría desestabilizar a los operadores tradicionales, al reducir su rentabilidad e incrementar sus

incentivos para asumir riesgos, transfiriendo la generación de riesgo sistémico a las entidades no bancarias.

Los reguladores deberán mantener unas condiciones equitativas entre participantes en el mercado, potenciando la innovación y manteniendo la estabilidad. Sin embargo, mantener unas condiciones equitativas es algo más fácil de decir que de hacer, atendiendo a la asimetría existente en los requisitos de intercambio de información de clientes en la banca abierta estipulados en la Directiva PSD2 (en relación con los operadores tradicionales) y el RGDP (que se aplica a los participantes no bancarios). La clave para mantener unas condiciones equitativas es permitir la interoperabilidad de datos entre los distintos proveedores de productos y servicios.

Los reguladores también deberán estar alerta ante las nuevas formas de riesgo sistémico. Por ejemplo, si la banca evolucionara hacia un sistema basado en plataformas, el riesgo de que se planteen problemas sistémicos derivados de ciberataques y filtraciones masivas de datos pasará a un primer plano. Además, las posibilidades de generar riesgos sistémicos por la contaminación entre las actividades bancarias y no bancarias aumentarían, así como el riesgo de quiebra de terceros proveedores. La decisión sobre qué actividades mantener dentro del perímetro normativo de los bancos tendrá consecuencias, ya que, si bien la regulación en función del ámbito de actividad puede fomentar la innovación y la igualdad de condiciones, son las entidades, y no las actividades, las que quiebran y pueden generar riesgos sistémicos.

Las preocupaciones en materia de protección del consumidor pasan a un primer plano. Los reguladores deberán, por ejemplo, determinar quién controla los datos (en este sentido, la UE parece ir por delante) y garantizar la seguridad cuando se realizan transacciones en las plataformas. Asimismo, tendrán que tomar en consideración que la tecnología digital permite una mayor capacidad de discriminación por precios, lo que también exige que se refuerce la protección del consumidor. Debe fomentarse especialmente el uso de la tecnología digital de una forma transparente que atenúe los posibles sesgos de comportamiento de consumidores e inversores. La transparencia en las condiciones a la hora de tratar con clientes es y seguirá siendo una ventaja competitiva de los bancos digitales que debería impregnar a todo el sector.

En conclusión, la regulación tiene que estar a la altura del reto de garantizar que la capacidad disruptiva de las nuevas tecnologías y plataformas para mejorar el bienestar se materialice en beneficios para los consumidores y las empresas, sin poner en peligro la estabilidad financiera.

#### NOTAS

(\*) Este documento presenta un resumen de otro titulado «Digital disruption in banking» preparado para la mesa redonda *FinTech* del Comité de Competencia de la OCDE de 5 de junio de 2019 y cuya revisión ha sido publicada en *Annual Review of Financial Economics* en diciembre de 2019. Mi más sincero agradecimiento a Ania Thiemann por sus minuciosos comentarios, a Antonio Capobianco por sus útiles sugerencias y a Giorgia Trupia y Orestis Vravosinos por su excelente ayuda en la investigación.

(1) Véase VIVES (2016, 2019a) para obtener una visión de conjunto de la competencia en el sector bancario, con especial atención a los acontecimientos recientes.

|                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                             |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                               |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <p>(2) <i>BigTech</i> se refiere a las grandes empresas tecnológicas que se basan en plataformas, como Amazon, Google o Apple.</p> <p>(3) La interfaz de programación de aplicaciones (API, por sus siglas en inglés) es un conjunto de normas y especificaciones que siguen los programas de <i>software</i> para comunicarse entre sí e intercambiar datos directamente sin necesidad de <i>inputs</i> humanos, y una interfaz entre distintos programas de <i>software</i> que facilita su interacción.</p> <p>(4) Algunos ejemplos de esto son las aplicaciones ofrecidas por firmas como Alibaba y Tencent en China y Grab en el sudeste asiático.</p> <p>(5) Véase la discusión en la sección 2.1 de VIVES (2019b).</p> <p>(6) «Un <i>sandbox</i> normativo es un espacio seguro en el que las empresas pueden testar productos, servicios, modelos de negocio y mecanismos de envío innovadores sin soportar de forma inmediata todas las consecuencias regulatorias habitualmente asociadas a la prestación de la actividad en cuestión». (Autoridad de Conducta Financiera del Reino Unido, 2015).</p> <p>(7) Uno de los primeros casos de nuevo participante que se benefició de la banca <i>online</i> fue ING en los años noventa. Un ejemplo de nuevo operador en el Reino Unido que utiliza sucursales y subcontrata la plataforma informática para reducir costes es METRO Bank, si bien ha tenido problemas para expandirse y ser rentable.</p> <p>(8) Otros casos serían Open Bank en España, propiedad del Santander, o Boursorama en Francia, propiedad de Société Générale.</p> <p>(9) Esta es la tesis que defienden DE LA MANO y PADILLA (2019).</p> <p>(10) En virtud de la PSD2, los bancos no podrán denegar a los proveedores de SIC el acceso a información sobre cuentas personales de banca <i>online</i> si los clientes lo autorizan.</p> <p>(11) DE LA MANO y PADILLA (2019) hacen hincapié en este punto.</p> | <p>(12) A esto deberíamos añadir la necesidad de combatir los riesgos de blanqueo de capitales asociados a las <i>fintechs</i>.</p> <p><b>BIBLIOGRAFÍA</b></p> <p>ABE (2017). EBA's Approach to Financial Technology (FinTech). <i>Discussion Paper</i> DP/2017/02.</p> <p>Carstens, A. (diciembre del 2018). Big Tech in Finance and New Challenges for Public Policy. Discurso de presentación en la FT Banking Summit, Londres.</p> <p>DE LA MANO, M. y PADILLA, J. (2019). Big Tech Banking. <i>Journal of Competition Law and Economics</i>. Disponible en doi.org/10.1093/joclec/nhz003</p> <p>DELOITTE (2018). <i>A Journey through the FCA Regulatory Sandbox</i>. Centre for Regulatory Strategy, EMEA.</p> <p>EY (2016). <i>UK FinTech - On the Cutting Edge: An Evaluation of the International FinTech Sector</i>. Disponible en: <a href="https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/502995/UK_FinTech_-_On_the_cutting_edge_-_Full_Report.pdf">assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/502995/UK_FinTech - On the cutting edge - Full Report.pdf</a></p> <p>FINANCIAL STABILITY BOARD (2019). <i>FinTech and Market Structure in Financial Services: Market Developments and Potential Financial Stability Implications</i>.</p> <p>FORO ECONÓMICO MUNDIAL (2017). Beyond Fintech: A Pragmatic Assessment of Disruptive Potential in Financial Services. <i>Future of Financial Services Series</i>.</p> | <p>GENEVA REPORTS ON THE WORLD ECONOMY (2018). <i>The Impact of Blockchain Technology on Finance: A Catalyst for Change</i>, n.º 21.</p> <p>KIM, S., PLOSSER, M. C. y SANTOS, J. A. C. (2017). Macroprudential Policy and the Revolving Door of Risk: Lessons from Leveraged Lending Guidance. <i>Staff Report</i>, n.º 815. Banco de la Reserva Federal de Nueva York.</p> <p>PHILIPPON, T. (2018). The Fintech Opportunity. <i>WP 2018-21</i>. Wharton School of the University of Pennsylvania Pension Research Council.</p> <p>THE ECONOMIST (9 de mayo del 2015). <i>The Bank in your Pocket</i>.</p> <p>VALLÉE, B. y ZENG, Y. (2019). Marketplace Lending: A New Banking Paradigm? <i>Review of Financial Studies</i>, 32(5), pp. 1939-1982.</p> <p>VIVES, X. (2016). <i>Competition and Stability in Banking: The Role of Competition Policy and Regulation</i>. Princeton: Princeton University Press, p. 344.</p> <p>— (2017). The Impact of Fintech on Banking. <i>European Economy – Banks, Regulation, and the Real Sector</i>, vol. 2, pp. 97-108.</p> <p>— (2019a). Competition and Stability in Modern Banking: A Post-Crisis Perspective. <i>International Journal of Industrial Organization</i>, n.º 64, pp. 55-69.</p> <p>— (2019b). Digital disruption in banking. <i>Annual Review of Financial Economics</i>, vol. 11, pp. 243-272.</p> |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|

## Resumen

Este artículo analiza los patrones que determinan la adopción y el uso frecuente de servicios financieros digitales entre los usuarios bancarios. Se realiza un ejercicio comparativo de las aportaciones econométricas tradicionales con otros dos métodos de análisis de información más recientes. En primer lugar, el aprendizaje automático (*machine learning*), con el objetivo de analizar la secuencia de decisiones que se sigue hasta convertirse en un usuario de servicios digitales financieros. Los resultados de este análisis sugieren que la consciencia sobre la gama de posibilidades de uso *online* y la consulta de información preceden a un uso frecuente de canales digitales para realizar transacciones. En segundo lugar, un análisis de resonancia magnética funcional para identificar si existen patrones neurológicos que expliquen diferencias entre los individuos en relación a su grado de digitalización financiera. Los resultados indican que existen patrones biológicos que pueden explicar diferencias en la predisposición a adoptar medios financieros digitales.

**Palabras clave:** digitalización financiera, aprendizaje automático, neuroeconomía.

## Abstract

This article analyses the adoption and frequency of use patterns of financial digitalization services among bank customers. It provides a comparison of standard econometric approaches with other two recent approaches to information analysis in this context. First of all, we use machine learning to study the sequence of decisions that describes the adoption of digital financial services. The findings suggest that both the awareness of the range of online service possibilities and information checking precede the use of financial services for transaction purposes. Secondly, we conduct a functional magnetic resonance exercise to identify if there are neurological patterns that explain differences in the adoption of digital services among bank customers. The results suggest that there are biological patterns explaining these differences.

**Keywords:** financial digitalization, machine learning, neuroeconomics.

**JEL classification:** D83, D87, G21.

# PATRONES DE ACCESO A LA BANCA DIGITAL: APROXIMACIONES TRADICIONALES, APRENDIZAJE AUTOMÁTICO Y NEUROECONOMÍA

Santiago CARBÓ VALVERDE (\*)

Francisco RODRÍGUEZ FERNÁNDEZ (\*\*)

Observatorio de la Digitalización Financiera de Funcas

## I. INTRODUCCIÓN. DIGITALIZACIÓN BANCARIA COMO FENÓMENO DE OFERTA Y DEMANDA

¿QUÉ hay detrás de la confusión y del posible cambio de paradigma en la economía del siglo XXI? ¿Por qué son menos predecibles los efectos de las acciones de los individuos, gobiernos y empresas? Responder a estas preguntas formará parte del reto de la profesión económica en los años venideros. Es probable que buena parte de las respuestas se refiera a los desafíos que impone el tratamiento de la información en la sociedad digital. El mundo financiero, como centro sobre el que gira gran parte de los mecanismos de inversión, no es ajeno a estos cambios. Por eso, cuando nos preguntamos qué hay detrás del comportamiento financiero en un entorno económico tan complejo cabría responder como el Sherlock Holmes de *Un escándalo en Bohemia*:

No poseo todavía datos. Constituye un craso error el teorizar sin poseer datos. Uno empieza de manera insensible a retorcer los hechos para acomodarlos a sus hipótesis, en vez de acomodar las hipótesis a los hechos.

Aunque Conan Doyle no estaría pensando en términos eco-

nómicos al escribir estas líneas, es posible que parte del razonamiento científico esté volviendo a tratar de dejar que sean los datos los que hablen por sí mismos porque ahora que contamos con técnicas para ello (englobadas en el análisis del *big data*) es posible que surjan nuevas teorías.

En este artículo se trata de ilustrar cómo diferentes aproximaciones a los datos pueden arrojar luz sobre un fenómeno de considerable relevancia económica y social: ¿cómo adoptan los consumidores los servicios financieros digitales? Cuantitativamente, 4.000 millones de personas en todo el mundo acceden a servicios *online* y los financieros y bancarios se encuentran entre los más destacados (OCDE, 2017). Como otros fenómenos económicos, las decisiones sobre con qué grado de digitalización realizar actividades financieras no son solamente una cuestión de demanda y de análisis de las preferencias reveladas. Estas decisiones están también significativamente influidas (si no orientadas) por variables de oferta: los medios y canales tecnológicos que las entidades financieras ponen a disposición de los clientes y el modo en que estos responden a sus necesidades. Conocer qué quiere realmente el cliente y diseñar una oferta digital financiera que produzca ganancias de bienestar (menos

costes y mejores servicios para todos) deviene extraordinariamente relevante. Se producen cada día millones de datos que deben ser sistematizados y que escapan al análisis convencional basado en encuestas para muestras limitadas y con un número reducido de variables para su adecuado tratamiento estadístico. Hoy es posible ordenar cantidades ingentes de datos y, sobre todo, de obtenerlos de nuevas fuentes, lo que da lugar a un número de variables muy elevado. En este artículo se trata de arrojar luz sobre las posibles aportaciones para aproximar las decisiones de digitalización financiera desde dos perspectivas:

- i) La profundidad de los datos y la capacidad para identificar, mediante el aprendizaje automático (*machine learning*), patrones de comportamiento.
- ii) La profundidad del comportamiento y la capacidad de la neuroeconomía para revelar factores determinantes de las decisiones de digitalización financiera que tienen un origen distintivo cerebral.

El artículo se estructura en cinco secciones que siguen a esta introducción. En la sección segunda se analizan las aproximaciones tradicionales al análisis de oferta y demanda en materia de digitalización y pagos y banca electrónica. La tercera sección se ocupa de las aportaciones que la neuroeconomía puede tener en este campo, ofreciendo un breve repaso, además, de la evolución reciente de esta disciplina. Dado que el caso español es la principal referencia para el análisis empírico en el artículo, la sección cuarta muestra las principales tendencias en digitalización financiera en España para

conformar perfiles y patrones descriptivos de digitalización. Los resultados de dos aproximaciones empíricas –*machine learning* y neuroeconomía– para el caso español se ofrecen en la quinta sección. La sección sexta recoge las principales conclusiones.

## II. APROXIMACIONES TRADICIONALES Y EL PAPEL DEL APRENDIZAJE AUTOMÁTICO

La inquietud científica respecto al fenómeno de la digitalización financiera responde tanto a cuestiones de índole social y de estabilidad financiera –beneficios y costes de compartir la información, privacidad, seguridad– como a las tendencias en la industria financiera para centrar los servicios en el cliente analizando sus necesidades con mayor profundidad. Un enfoque al que genéricamente se ha denominado *customer centric* (McKenna, Tuunanen y Gardner, 2013). Esto sugeriría que las principales tendencias de digitalización están influenciadas por cambios en la demanda (Campbell y Frei, 2010), pero es difícil identificar en qué medida no es la oferta la que genera una mayor inclinación hacia la digitalización y, al mismo tiempo, estimula la competencia entre proveedores por ofrecer servicios más inmediatos y a un menor coste (Hernández-Murillo, Llobet y Fuentes, 2010).


En lo que a servicios financieros se refiere, la mayor parte de estudios hasta la fecha se han centrado en los determinantes de la adopción de banca *online*. En un principio, entendida como el uso de medios de pago por Internet y, en general, electrónicos. Más recientemente, entendida también como servi-

cios de banca *online*. El enfoque científico estándar es el uso de encuestas sobre la adopción de medios digitales y su tratamiento mediante modelos de respuesta binaria tipo *logit* o *probit*. En estos, la variable latente es la adopción o no de un servicio digital y los posibles determinantes incluyen variables sociodemográficas (multinomiales) y otras relativas a la valoración de atributos de esos servicios (condicionales). Los resultados de estas investigaciones señalan que la percepción de seguridad, utilidad, calidad y conveniencia del servicio, junto a factores sociodemográficos como la edad o el nivel de ingresos, son los principales determinantes de la adopción de servicios financieros *online* (Casaló, Flavián y Guinalíu, 2007; Hoehle, Scornavacca y Huff, 2012; Laukkanen, 2016; Loureiro *et al.*, 2014; Yoon y Barker Steege, 2013; Yusuf Dauda y Lee, 2015). Estos factores, no obstante, pueden tener una incidencia distinta dependiendo de la etapa general de adopción tecnológica en que se encuentre una determinada población e, incluso, de su raigambre cultural (Jaruwachirathanakul y Fink, 2005; Kesharwani, 2019; Tam y Oliveira, 2019). El gráfico 1 resume las aportaciones y limitaciones de las aproximaciones econométricas tradicionales respecto al aprendizaje automático, con las lecciones que ello implica para el estudio de los patrones de digitalización financiera.

La mayor parte de los estudios hasta la fecha se han centrado en la adopción de pagos electrónicos (tarjeta, compras *online*) o de servicios bancarios *online*. Sin embargo, es difícil delimitar aspectos tan trascendentes



GRÁFICO 1

**DIGITALIZACIÓN FINANCIERA: APROXIMACIONES ECONÓMICAS PARAMÉTRICAS VS. MACHINE LEARNING**

Fuente: Elaboración propia.

como qué lleva a un consumidor a optar por servicios financieros digitales, por qué fases atraviesa, qué grado de diversificación puede llegar a tener y hasta qué punto está dispuesto a abandonar completamente patrones tradicionales como acudir a una oficina o firmar un contrato físico. Muchas de estas respuestas pueden estar en los procesos de decisión que estima y simula el aprendizaje automático o *machine learning*. Se trata de un tipo de análisis que, en lugar de realizar supuestos excesivamente simplificadores respecto a la estructura de los datos, permite identificar pautas complejas (Bishop, 2016). En este sentido, el aprendizaje automático ha sur-

gido en este campo para cubrir las lagunas que otros modelos –generalmente englobados como «modelos de adopción tecnológica» o TAM, por sus siglas en inglés– no han podido explicar sobre la digitalización financiera (Bagozzi, 2007; Pousttchi y Dehnert, 2018).

El aprendizaje automático se fundamenta en algoritmos que aproximan las pautas de decisión. Esto no implica que los modelos TAM (véase Davis, Bagozzi y Warshaw, 1989) no ofrezcan resultados de interés. Lo que ocurre es que los modelos TAM suelen poner una ponderación excesivamente excluyente en la percepción de la utilidad de uso de la tecno-

logía. En todo caso, estos estudios han ido ampliando su enfoque en los últimos treinta años para añadir cada vez más características de oferta y no únicamente factores relacionados con la percepción de los usuarios. Aun no siendo excluyentes, las motivaciones principales para la adopción de banca *online* identificadas han sido diversas. Entre ellas, la seguridad (Casaló, Flavián y Guinalíu, 2007; Cheng *et al.*, 2006; Hoehle, Scornavacca y Huff, 2012; o Yoon y Barker, 2013), la facilidad de uso (Aldás-Manzano *et al.*, 2009; Lee, 2009; Loureiro *et al.*, 2014) o el coste (Huang *et al.*, 2003; Laukkanen, 2016).

Aunque los estudios específicos sobre la comparación de canales tradicionales y digitales no son abundantes, algunos sugieren que un factor crítico en los usuarios que prefieren canales digitales en lugar de servicios en oficina es el nivel de ingresos del cliente (Hitt y Frei, 2002). Otros añaden que la experiencia de otros productos con la misma entidad (tarjetas de crédito, hipotecas) puede aportar la seguridad necesaria para adoptar servicios *online* (Szopiński, 2016). Más recientemente, se han prologado los estudios sobre el canal más digital y ubicuo en los últimos años para la banca *online*: el *smartphone*. Los estudios sobre adopción de «banca móvil» han seguido, metodológicamente, un enfoque similar al de la banca *online* general. En este caso, la edad aparece como un factor particularmente decisivo (Lu *et al.*, 2015; Susanto, Chang, y Ha, 2016; Alalwan, Dwivedi y Rana, 2017), aunque otros como la percepción de seguridad y la confianza en el dispositivo móvil también han sido identificados como importantes (Dahlberg, Guo y Ondrus, 2015). Xu *et al.*



(2011) señalan que cuando los clientes optan por canales digitales, adquieren más productos del banco y diversifican el número de transacciones. En esta línea, Campbell y Frei (2010) señalan que existe una relación positiva entre el uso de banca *online* y la fidelidad de la clientela.

### III. NEUROECONOMÍA Y SUS POSIBLES APORTACIONES AL FENÓMENO DE LA DIGITALIZACIÓN

¿Qué puede aportar la neuroeconomía en el tratamiento de la información en la era de la digitalización? La pregunta surge de la aparente paradoja de que en un mundo de abundancia de datos externos, la actividad cerebral de un individuo pueda ser de utilidad para comprender su toma de decisiones más allá de lo que hasta ahora hemos conocido. En cierto modo, formaría parte de ese *small data* o *smart data* que recoge cuestiones que, sin requerir de complejos algoritmos para su tratamiento, pueden arrojar nueva evidencia. Como disciplina, la neuroeconomía tuvo su principal campo de expansión hacia finales de la década de 1990, producto de la convergencia de varias aproximaciones de la economía del comportamiento, la psicología y la neurología (1).

La deducción de funciones de utilidad a partir del comportamiento del consumidor (preferencias reveladas) de la teoría neoclásica tuvo una respuesta crítica por parte de los economistas del comportamiento, que fueron demostrando, con evidencia experimental, la falibilidad de algunos de los principales axiomas de las preferencias del consumidor. La reacción de los

economistas neoclásicos –con generalizaciones y mejoras de los modelos al uso– encontró también una nueva respuesta por parte de los experimentalistas, que trataron de dar un mayor soporte teórico a sus resultados empíricos. Así, por ejemplo, los seguidores de las teorías neoclásicas propusieron modelos en los que si dos agentes (p. ej. consumidores) seguían un comportamiento ineficiente, no significaba que los axiomas tradicionales no tuvieran sentido ya que podría ser una excepción explicada por la existencia de un equilibrio conflictivo entre sus intereses mutuos. Cuando son muchos los agentes que interactúan, aumenta también la complejidad computacional del equilibrio entre ellos. La psicología evolutiva (y la economía del comportamiento) identifica muchos de estos procesos complejos con actividad cerebral que difieren entre los individuos. En este punto es donde, desde un origen neurológico, la complejidad de las decisiones requiere de la capacidad de computación que ofrecen los algoritmos, surgiendo, por lo tanto, un campo de colaboración y expansión entre disciplinas como el análisis del *big data*, la inteligencia artificial, la economía, la neurología y la psicología. Sin embargo, con la entrada del siglo XXI, aún no existía un marco teórico de referencia para hilar estas disciplinas (Glimcher, 2002).

Con el comienzo del siglo XXI se fueron prodigando aportaciones de economistas neoclásicos que trataban de identificar conductas complejas mediante computación algorítmica al tiempo que los economistas del comportamiento utilizaron progresivamente técnicas de imagen cerebral para desarrollar

modelos teóricos alternativos sobre el comportamiento de los individuos. No todos los resultados resultan, hasta la fecha, en una senda convergente, pero se están produciendo algunos de los más importantes avances en muchas décadas (véase Camerer, Loewenstein y Prelec, 2005).

Entre las contribuciones con aportaciones pioneras a la nueva teoría de decisión, destacaron dos. En la primera, Breiter *et al.* (2001) hicieron uso de imágenes de resonancia magnética funcional (*fMRI*, por sus siglas en inglés) para evaluar la teoría prospectiva de Kahneman y Tversky. Se trata de un modelo «no normativo» de la teoría de la utilidad que había inspirado ya investigaciones importantes en el campo experimental. La teoría prospectiva sugiere que un resultado económico pobre (por ejemplo, una ganancia de cero dólares) de una interacción puede ser visto inicialmente como negativo por los participantes, pero podría acabar siendo visto como menos negativo si fuera el mejor de los resultados posibles (si el resto de opciones fuera aún peor). Esta valoración subjetiva fue confirmada por diferencias en la actividad cerebral (en particular, del estriado ventral) en el experimento de *fMRI*. En la segunda contribución, McCabe *et al.* (2001) examinaron por vez primera la actividad cerebral en un juego estratégico de confianza (*trust game*). Sus resultados sugieren que la actividad de la corteza prefrontal cerebral es mayor cuando las estrategias de los individuos se desvían de los supuestos normativos que la teoría predice para ese juego.

Las decisiones financieras –como las relacionadas con la di-

gitalización que examinamos en este artículo— también han sido objeto de atención por parte de la neuroeconomía. Se trata de cuestiones importantes en la medida en que los estudios seminales sobre comportamiento han demostrado la racionalidad limitada de muchas decisiones económicas. En este sentido, pueden derivarse lecciones importantes de cultura financiera con implicaciones para la riqueza y la igualdad. Han sido varios los estudios que han señalado que pueden existir restricciones cognitivas que, combinadas con un nivel reducido de cultura financiera, pueden llevar a la toma de decisiones sobre ahorro o inversión que violan algunos principios financieros básicos (Benartzi y Thaler, 2007; Campbell, 2006 y 2016; Sonnemann *et al.*, 2013; Keys, Pope y Popec, 2016; Frydman y Camerer, 2016).

En la medida en que los canales digitales surgen como vía para tomar decisiones financieras, cabe preguntarse hasta qué punto los parámetros de confianza y adopción de riesgo propios de estas decisiones pueden verse alterados. Esto resulta más relevante si se tiene en cuenta que existen diferencias importantes, poblacionales y territoriales, en el grado de adopción de la digitalización financiera.

Un aspecto esencial para el análisis es la distinción entre la naturaleza no humana de las conexiones digitales y la interacción humana propia de los canales tradicionales (oficinas, empleados). En lo que respecta a la confianza, su importante papel en la mayor parte de las transacciones económicas se extiende a los entornos digitales (Bart *et al.*, 2005; Wang y Emurian, 2005). Se han desarrollado también estudios que analizan la relación


entre la confianza y la activación de varias regiones cerebrales en entornos de interacción humana (Baumgartner *et al.*, 2008; Delgado y Phelps, 2005; King-Casas *et al.*, 2005; Krueger *et al.*, 2007). Más recientemente, se han desarrollado también investigaciones de neuroeconomía relacionadas con entornos *online* (Dimoka, 2010; Riedl *et al.*, 2014). Los principales resultados de estos estudios revelan que regiones cerebrales como el estrato, cíngulo, la estructura prefrontal y la ínsula presentan una activación relacionada con la confianza en el entorno digital.

En la medida en que la mayoría de las decisiones financieras entrañan lidiar con parámetros de riesgo, un cambio en los canales que definen esas decisiones parece, asimismo, importante (gráfico 2). La mayor parte de los análisis de neuroeconomía en este contexto corresponden al comportamiento de los *traders* en decisiones de inversión ante la disyuntiva básica entre rentabilidad e incertidumbre. En esta línea, diferentes estudios demuestran que la actividad de la ínsula anterior se relaciona con el grado de riesgo adoptado (más activación, menos riesgo) (Knutson *et al.*, 2003; Kuhnen y Knutson, 2005 y 2011; Knutson y Bossaerts, 2007; Pruschoff, 2008; Rudolf, Preuschoff y Weber, 2012; Häusler *et al.*, 2018). Este resultado respecto a la ínsula anterior es similar al de estudios que comparan las reacciones neuronales en situaciones de incertidumbre y dolor físico (Preuschoff, Bossaerts y Quartz, 2006).

También relacionado con el riesgo existen factores como la impulsividad y la percepción de los mecanismos de recompensa.

GRÁFICO 2

### **BIG DATA Y SMART DATA EN LA DIGITALIZACIÓN FINANCIERA: LA APORTACIÓN DE LA NEUROECONOMÍA**



Fuente: Elaboración propia.

Se ha demostrado que, en determinados entornos, son factores inconscientes neurológicos los que explican el comportamiento impulsivo (Hubert *et al.*, 2013). De hecho, la impulsividad se ha relacionado con un conjunto de regiones cerebrales a las que se denomina «sistema de recompensa», que registra cómo se percibe el estímulo o la decepción como relación entre la expectativa y los resultados (Elliott, Friston y Dolan, 2000). Los estudios mediante *fMRI* han demostrado que el procesamiento y anticipación de las recompensas está relacionado con la actividad del estrato (O'Doherty *et al.*, 2004; Fareri y Delgado, 2012). En comparación con los canales tradicionales, los canales digitales también incorporan potenciales mecanismos de recompensa (como ahorro de tiempo o menores comisiones) que pueden afectar a la impulsividad. Breiter *et al.* (2001) muestran que el núcleo accumbens, la amígdala extendida sublenticular (*SLEA*, por sus siglas en inglés) y el hipotálamo procesan los mecanismos de recompensa monetarios de la misma manera que lo hacen los estímulos al tacto, gustativos o la euforia inducida mediante drogas. Aunque estas cuestiones no han sido estudiadas en relación con las decisiones de digitalización financiera, sí existe alguna evidencia cuando se comparan interacciones económicas humanas e interacciones digitales. Los resultados de Huettel *et al.* (2006) o Mohr *et al.* (2010) sugieren que los individuos prefieren sacrificar recompensas potenciales en el futuro por seguridad en el momento presente, lo que está correlacionado con actividad cerebral en regiones como la ínsula.

En su conjunto, se trata de una disciplina con un campo de ex-

pansión evidente no solo para contrastar la formalidad de axiomas neoclásicos, sino, de forma más general, con una utilidad para dilucidar hasta qué punto la actividad cerebral muestra pautas de comportamiento no identificables por otras vías de análisis económico y estadístico convencionales.

#### IV. LA DIGITALIZACIÓN FINANCIERA EN ESPAÑA: ENFOQUE METODOLÓGICO Y PRINCIPALES PERFILES

##### 1. Datos y perfil del cliente digital en España

Los datos para el estudio de la digitalización financiera parten de una encuesta sobre usos de servicios bancarios y de pago relacionados con la digitalización desarrollada en el seno del Observatorio de la Digitalización Financiera (ODF) de Funcas. La base metodológica de la encuesta es el *Survey of Consumer Payment Choice (SCPC)* realizado por el Federal Reserve Bank of Boston.

La encuesta del ODF fue realizada por IMOP entre noviembre y diciembre de 2016 y ha contado con ampliaciones entre 2017 y 2019 (2). El universo encuestado se refiere a residentes en el territorio nacional peninsular e insular de 18 a 75 años. El tamaño muestral es de 3.005 encuestados telefónicamente con cuotas controladas de representación sociológica según edad, sexo y localización. Los métodos de ponderación corresponden a los del estudio general de medios (EGM) de la Asociación para la Investigación de Medios de Comunicación (AIMC). El error muestral se estima en un  $\pm 1,8$  por 100. Si se analizan las características del cliente que usa servicios financieros digitales (banca *online*, banca móvil) de forma frecuente (diaria o semanalmente), se obtiene un perfil como el descrito en el cuadro n.º 1. Se cumplen algunos parámetros de expectativa lógica como el ser usuario habitual de Internet y de *smartphone*. Otros datos apuntan a un usuario preponderantemente femenino en poblaciones medianas o grandes y con uso frecuente de medios

CUADRO N.º 1

##### PERFIL DEL CLIENTE FINANCIERO DIGITAL EN ESPAÑA

| CARACTERÍSTICA                                     | INCIDENCIA MUESTRAL (PORCENTAJE SOBRE EL TOTAL DE ENCUESTADOS) |
|----------------------------------------------------|----------------------------------------------------------------|
| Usuario habitual de Internet                       | 92,0                                                           |
| Usuario de <i>smartphone</i>                       | 85,3                                                           |
| Mujer                                              | Aproximación a la mediana del cliente digitalizado             |
| 39 años                                            | Aproximación a la mediana del cliente digitalizado             |
| Vive en una población de más de 200.000 habitantes | Aproximación a la mediana del cliente digitalizado             |
| Ingresos en el hogar entre 3.000 y 5.000 euros     | Aproximación a la mediana del cliente digitalizado             |
| Con tarjeta de débito                              | 71,9                                                           |
| Con tarjeta de crédito                             | 50,8%                                                          |
| Consulta saldos y movimientos bancarios            | 68,2                                                           |

Fuente: Observatorio de la Digitalización Financiera de Funcas.

de pago electrónicos (tarjeta de débito y crédito).

Se trata del perfil con el que la aproximación econométrica paramétrica tradicional puede estimar el impacto marginal de cada característica en la probabilidad de ser un usuario frecuente de servicios digitales.

## 2. La relación del cliente español con su proveedor de servicios financieros y el impacto de la digitalización

Otra dimensión importante, como se muestra en la sección, es cómo se producen las relaciones de confianza y de percepción del riesgo cuando se adoptan servicios financieros digitales. La encuesta de ODF permite comparar las diferencias de percepción entre banca tradicional, banca *online* y banca móvil (cuadro nº. 2). Algunos datos ilustran por qué la banca *online* tiene un proceso de adopción progresivo. Mientras que el 88,8 por 100 considera los servicios de banca tradicional como seguros o muy seguros, únicamente el 54,8 por 100 lo considera así para la banca *online* y el 44,2 por 100 para la banca móvil. Desde el punto de vista de la racionalidad económica, otras percepciones resultan algo sorprendentes. Resulta llamativo que solamente el 63,2 por 100 considere la banca *online* como de coste bajo o muy bajo y el 58,8 por 100 la banca móvil, frente a porcentajes más altos de servicios tradicionales. La realidad muestra que, objetivamente, los canales digitales suponen un ahorro tanto directo (menos comisiones) como indirecto (más ahorro de tiempo). La interacción con el dispositivo parece importante en este punto. El 90 por 100 creé

que los canales tradicionales son sencillos y muy sencillos frente al 67,8 por 100 que lo considera para la banca *online* y el 64,4 por 100 que así lo cree para la banca móvil. Se observan diferencias similares cuando se analizan aspectos como lo práctico que resulta el canal o la calidad de la información que proporciona. En cuanto a la incertidumbre, se revela como un factor importante de decisión dado que el 84,3 por 100 considera la banca tradicional como poco o nada arriesgada, mientras que ese porcentaje es únicamente del 43,4 por 100 y del 35,6 por 100 para los canales *online* y la operativa con *smartphone*, respectivamente.

Teniendo en cuenta estas observaciones, es conveniente plantear dos cuestiones:

- Dado que existen diferencias en cómo se estructura la confianza y se percibe el riesgo en función del grado de digitalización del canal ¿qué secuencia de decisiones siguen los clientes que acaban digitalizándose de forma significativa en su actividad bancaria?
- Puesto que existen elementos objetivos (menor coste, mayor velocidad) a favor de los canales digitales que los usuarios no parecen percibir, cabe pre-

guntarse si concurren factores de conducta o neurológicos que alientan o desincentivan la predisposición a digitalizarse.

En la siguiente sección se trata de responder a estas dos cuestiones. Se trata de los resultados de dos investigaciones en curso del ODF de Funcas, una sobre aprendizaje automático –para aproximar la secuencia de decisiones de digitalización financiera– y otra de neuroeconomía –para explorar la actividad cerebral ante medios financieros digitales–.

## V. EVIDENCIA EMPÍRICA

### 1. Del enfoque estándar al aprendizaje automático

La aproximación de aprendizaje automático a la secuencia de decisiones que explican la digitalización financiera es el algoritmo del bosque aleatorio (*random forest*) (3). Se trata de una técnica que utiliza una combinación de árboles de decisión o de clasificación, basados en la incorporación aleatoria de un conjunto de características contenidas en un conjunto de datos, para realizar predicciones sobre clasificaciones o decisiones. Estos sistemas permiten usar algoritmos para identificar patrones complejos en millones de datos

CUADRO N.º 2

#### PERCEPCIONES DE LOS CLIENTES SOBRE LA CONFIANZA Y SEGURIDAD DE LOS CANALES BANCARIOS (PORCENTAJE DE ENCUESTADOS)

|                               | BANCA TRADICIONAL | BANCA ONLINE | BANCA MÓVIL |
|-------------------------------|-------------------|--------------|-------------|
| Seguro o muy seguro           | 88,8              | 54,8         | 44,2        |
| Coste bajo o muy bajo         | 70,1              | 63,2         | 58,8        |
| Uso sencillo o muy sencillo   | 90,0              | 67,8         | 64,4        |
| Práctico o muy práctico       | 81,2              | 68,8         | 61,9        |
| Información buena o muy buena | 82,8              | 65,9         | 76,1        |
| Poco o nada arriesgado        | 84,3              | 43,4         | 35,6        |

Fuente: Observatorio de la Digitalización Financiera de Funcas.



con los que realizar una predicción futura. Los árboles de decisión empleados en el *random forest* se generan a partir del establecimiento de un conjunto de reglas que permiten secuenciar una toma de decisiones en un conjunto de pasos que se construyen siguiendo una lógica.

El proceso consiste en la generación de cientos de árboles de decisión aleatoriamente, mediante repeticiones, lo que permite extraer de algunos de ellos las secuencias de decisión más comunes e identificar qué características (variables) son las que aparecen con mayor frecuencia como definitorias de cada decisión o clasificación. Mientras que los modelos econométricos son capaces de establecer y cuantificar las relaciones de causalidad que existen entre las variables estudiadas, la técnica del *random forest* permite establecer una secuenciación acerca del impacto que tienen dichas variables en el resultado final. Esta técnica no establece relaciones de causalidad, sino que identifica patrones a partir de los cuales poder predecir cómo se establecen relaciones. El bosque aleatorio, indica, ordenadamente, las variables (por ejemplo: facilidad de uso, coste, seguridad, ...) que determinan que un individuo utilice o no un servicio financiero digital. Este análisis cobra importancia en la medida en que permite señalar, por ejemplo, si las opiniones divergentes acerca de la facilidad de uso ayudan en mayor o menor medida a discriminar individuos que utilizan la tarjeta de crédito frente a otros que no lo hacen. En este sentido, los factores que permitan distinguir mejor a los usuarios de los no usuarios serán considerados como de primer orden. Por tanto, a partir del *random forest* se podrían conocer

los factores que principalmente influyen en la toma de decisiones frente a aquellos que inciden, pero que son de segundo orden o menos discriminantes.

La dimensión estudiada en la adopción es la frecuencia de uso de los servicios financieros *online*. A partir del conjunto de variables sociodemográficas, de digitalización general (medios y usos digitales), de digitalización financiera (medios y usos financieros digitales) y de percepciones sobre cualidades de determinados servicios (calidad, seguridad, facilidad de uso...) se procede a clasificar a los individuos en tres tipos de usuarios en función del grado en que se ha digitalizado sus actividad financiera. Los grupos de usuarios representativos que se definen son:

- No usuarios (F): recoge al conjunto de individuos que están fuera de la digitalización financiera porque tampoco tienen un grado de digitalización general suficiente.
- Usuarios poco/muy poco frecuentes (N): formado por aquellos que realizan operaciones de compra y otras operaciones financieras y consultas *online* (ambas) pero de manera esporádica, es decir, una vez al año, nunca o casi nunca.
- Usuarios frecuentes (S): integrado por aquellos individuos que realizan operaciones de compra y otras operaciones financieras y consultas *online* (ambas) al menos una vez a la semana o varias veces durante un mes.

A través del *random forest* se construyen aleatoriamente 500 árboles de decisión con un conjunto características que permite clasificar a los individuos de

la encuesta en cada uno de los tres tipos de usuarios. El primer resultado revela cuáles son las variables que reducen en mayor medida el error de estimación (*mean decrease accuracy*) y que permiten encontrar la mayor similitud entre los árboles comparados (*mean decrease Gini*):


- Consulta de saldos financieros (Internet saldos): En la medida en que exista la necesidad de consultar los saldos a través de Internet, ya sea el de su cuenta bancaria o el de un medio de pago, el usuario irá digitalizándose financieramente.
- Consciencia: es una variable que muestra la ratio entre el número de cuentas que el usuario cree que tienen acceso *online* entre el número de cuentas que efectivamente tienen acceso *online*. Es la medida en que el individuo es consciente de la existencia de servicios *online* este irá digitalizándose financieramente.
- Pago de facturas (Internet facturas): en la medida en que el individuo pague sus facturas *online*, el usuario irá digitalizándose financieramente.

A partir de dichos factores de primer orden podemos establecer un árbol de decisión (gráfico 3) capaz de predecir acertadamente (en un 90 por 100 de los casos) a qué tipo de grupo de usuarios pertenece cada individuo encuestado. En este árbol se muestra que la secuencia que siguen los usuarios de banca para usar cuentas *online* pasa primero por consultar frecuentemente saldos, posteriormente por ser consciente de otras posibilidades que ofrece el uso de la banca *online* y finalmente por pagos por Internet para comprobar su fiabilidad.



GRÁFICO 3

SECUENCIA QUE EXPLICA LA ADOPCIÓN FRECUENTE DE SERVICIOS FINANCIEROS DIGITALES SEGÚN LAS ESTIMACIONES DE *RANDOM FOREST*



Fuente: Estimaciones de los autores a partir de los datos de la encuesta.

Las estimaciones no permiten únicamente aproximar el proceso de decisión, sino el número de veces que debe repetirse (en promedio) cada eslabón del mismo para llegar al resultado final. En este sentido, una vez que se han realizado al menos dos pagos *online*, es frecuente convertirse ya en un usuario asiduo de servicios financieros digitales.

## 2. Una aproximación preliminar a la caracterización neurológica

El objetivo de utilizar imágenes de resonancia magnética funcio-

nal (*fMRI*) es identificar si existen marcadores de neuroimagen relacionados con distintos patrones de comportamiento en el uso de los medios financieros digitales (4). En particular, se trata de investigar si existen características en la estructura cerebral ligadas al comportamiento financiero digital.

En cuanto a la muestra, 121 personas fueron seleccionadas a partir de las respuestas obtenidas en un cuestionario sobre digitalización financiera que replica el realizado por IMOP para Funcas y que se explica en la quinta sección en su primer epígrafe. Los participantes fueron divididos en tres grupos según su respuesta a

la pregunta: ¿Con qué frecuencia utiliza servicios online (incluidos Internet y *apps* móviles) para consultar sus cuentas y/o realizar transacciones? Así, se asignaron 41 personas que contestaron nunca o casi nunca a un primer grupo (GN), 40 a un grupo de uso mensual (GM) y 40 a un grupo de uso semanal o de frecuencia habitual (GS). Los grupos replican la distribución de sexo, estado laboral e ingresos familiares que es representativa poblacionalmente. La población de referencia era estudiantes universitarios de entre 18 y 31 años. Esto reduce la variabilidad geográfica e incrementa la probabilidad de que los individuos cuenten con un grado de digitali-

zación medio mayor al promedio de la población española, pero reduce la probabilidad de que las diferencias encontradas entre grupos respondan a esos factores (grado general de digitalización o edad).


El primer ejercicio experimental con resonancia magnética funcional se trataba de una tarea en la cual los participantes debían observar una serie de vídeos de personas utilizando distintas formas de gestión del dinero, mientras se obtenían imágenes funcionales de su cerebro. Además, después de cada vídeo, se les preguntaba el nivel de seguridad que les generaba la acción que acababan de observar, debiendo responder a la pregunta, *¿Qué seguridad te genera esta acción?*, en una escala del 1 al 4. Se seleccionaron siete situaciones que involucran distintas formas de intercambio de dinero y se prepararon dos vídeos de quince segundos de cada una. En cada vídeo se observaba a una persona realizando esa acción. Con el fin de posibilitar comparaciones con vídeos con contenido emocional, se incluyeron dos condiciones de vídeos agradables (paisajes relajantes) y desagradables (insectos y basura). Cada participante visionó cada vídeo dos veces. Las siete condiciones económicas seleccionadas fueron: sacar dinero de un cajero automático, pago en efectivo, pago con móvil, pago con reloj, pago con tarjeta, realización de una transferencia *online* y realización de una transferencia vía Paypal. Los individuos respondieron a preguntas sobre la seguridad y confianza de las alternativas de pago. Cuando se les preguntó *¿Qué seguridad le proporciona esta acción?* el efectivo y el cajero resultaron las más seguras (en consonancia con los resultados generales de la en-

cuesta), pero lo más relevante es que no se encontraron diferencias significativas en la seguridad atribuida a cada servicio de pago entre los grupos de individuos con distinto nivel de digitalización financiera. A escala cerebral, sin embargo, sí se observaron algunas diferencias de interés. Los resultados obtenidos permiten observar qué áreas del cerebro están vinculadas con la seguridad en el pago, o dicho de otro modo, las áreas que aparecen activadas, lo están más cuando la situación se percibe como más segura. A nivel global (sin dividir entre grupos) se encuentra que la seguridad se relaciona con mayor activación de áreas de la red cerebral por defecto, así como del lóbulo occipital, y de regiones subcorticales, y las cortezas motora y parietal inferior izquierdas. Por el contrario los vídeos donde se percibe

menor seguridad se asocian con la activación de la corteza motora derecha y la corteza parietal inferior derecha. Por tanto, la seguridad en los pagos se asocia a la activación de la red cerebral por defecto, del lóbulo occipital y de regiones subcorticales como el tálamo y el núcleo accumbens, en consonancia con otros estudios de neuroeconomía. Cuando comparamos entre los grupos, podemos observar como el grupo de mayor digitalización financiera (de uso semanal o mayor) en comparación con el que no usa medios digitales, activa más la región frontal superior, relacionada entre otras funciones con las funciones ejecutivas y, por ejemplo, la planificación y también activa más el caudado dorsal, una región relacionada con los hábitos de conducta (gráfico 4).

GRÁFICO 4

**REGIONES QUE MUESTRAN UNA MAYOR ACTIVACIÓN EN EL GRUPO DE MAYOR USO DE MEDIOS FINANCIEROS DIGITALES COMPARADO CON LOS DE USO MEDIO Y ESCASO O NULO**



Fuente: Carbó, Cuadros y Rodríguez (2019).

Junto con la seguridad que las personas puedan percibir de los distintos medios financieros digitales, es interesante evaluar si en su uso también influye la confianza que depositan en otras personas o en sistemas electrónicos que dan respuestas aleatorias. Con la idea de evaluar los sustratos cerebrales asociados a la confianza interpersonal, se utilizó el «juego de la confianza» (*trust game*) de modo similar a la implementada en su estudio por Baumgartner (2008) (5). De nuevo no hay diferencias estadísticamente significativas entre los grupos en el juego en sí, aunque sí se observa un cierto patrón por el cual las personas que no utilizan los medios financieros digitales ceden más dinero cuando se trata de una persona, que cuando se trata de una máquina, siendo el patrón al revés en los otros dos grupos. Con respecto al análisis cerebral, en lo que respecta a la confianza se encontró una amplia activación cerebral que incluía regiones somatosensoriales y motoras, del cíngulo anterior y posterior, el precuneus, el cerebelo, áreas visuales, el hipocampo y el núcleo accumbens. Este patrón es muy intenso en el grupo de uso semanal a diferencia de lo que sucede en los grupos de menos uso de medios digitales. En cuanto al procesamiento relacionado con los ensayos en los que se jugaba con la máquina, se obtiene a nivel global una activación de regiones frontolaterales. En este caso ocurre lo contrario que anteriormente siendo este patrón el menos intenso en el grupo de uso frecuente de medios digitales. Los resultados del estudio (aquí mostrados únicamente de forma parcial por simplicidad expositiva) sugieren que existen sustratos biológicos que fundamentan las diferencias en el uso

de los medios financieros y que son distintos en función de la frecuencia de uso.

## VI. CONCLUSIONES

El análisis de la información ha encontrado nuevos campos de expansión en los avances científicos relacionados con la digitalización, y el mundo financiero es de particular interés en este tipo de investigaciones. En este artículo se analiza cómo los individuos adoptan medios digitales para sus actividades financieras, comparando los enfoques econométricos tradicionales con dos técnicas de análisis de datos y de comportamiento recientes. Por un lado, se emplean métodos de aprendizaje automático para tratar de simular la secuencia de decisiones que llevan a una adopción y uso frecuente de medios financieros digitales. Por otro lado, se emplean técnicas de resonancia magnética funcional para estudiar la activación cerebral en el uso de servicios financieros con distinto grado de digitalización.

El análisis resume algunas de las investigaciones amplias que se están desarrollando en el seno del Observatorio de la Digitalización Financiera (ODF) de Funcas, con aplicaciones al caso español. Los resultados del análisis de aprendizaje automático sugieren que la consciencia sobre la variedad de los servicios digitales disponibles y la consulta de información financiera *online* son pasos previos al uso frecuente de medios digitales para transacciones financieras. En cuanto al análisis relativo a la activación cerebral, se encuentra que existen patrones biológicos con un desarrollo particularmente activo entre la población que más intensamente utiliza los canales

digitales para sus transacciones financieras.

En un tiempo en el que los proveedores de servicios financieros se esfuerzan por adecuar su oferta a los cambios en la demanda y en el que existe una apuesta decidida por una agenda digital, aportar nuevas vías para entender el camino por el cual los ciudadanos optan por la digitalización en cuestiones tan trascendentes como sus operaciones financieras se antoja de significativo interés científico y utilidad social.

## NOTAS

(\*) Otras afiliaciones: CUNEF y Bangor University.

(\*\*) Otra afiliación: Universidad de Granada.

(1) Una aproximación exhaustiva de la evolución de la neuroeconomía puede encontrarse en GLIMCHER y FEHR (2013).

(2) Los detalles de las distintas encuestas pueden consultarse en [https://www.funcas.es/\\_obsdigi/](https://www.funcas.es/_obsdigi/).

(3) Los resultados aquí mostrados son parte de una investigación más general desarrollada en el ODF-Funcas, referenciada como CARBÓ *et al.* (2019a).

(4) Este apartado resume algunos resultados parciales de la investigación desarrollada para el ODF de Funcas por CARBÓ *et al.* (2019).

(5) En esta tarea los participantes comienzan cada ensayo con una cantidad de dinero fija, 12 euros, y deben elegir cuánto de ese dinero ceder a un segundo jugador, jugador B, que parte también de una situación inicial de 12 euros. La cantidad cedida se multiplicará por tres y en ese momento el jugador B puede elegir devolver una parte al primero. Para facilitar la tarea, las cantidades a ceder están restringidas a cuatro valores, (0, 4, 8 o 12 euros) y el jugador B siempre devolverá la mitad de lo recibido, en cuyo caso el jugador A siempre termina con más dinero que el inicial, o nada (0 euros). Los participantes eligen pulsando uno de los cuatro botones que se les proporcionan dentro de la resonancia magnética. En nuestro caso el juego se repite hasta un total de 24 ensayos, donde en la mitad de ellos el

jugador B será una persona, que devolverá el dinero en función de su interés, y en la otra mitad el jugador B será una máquina que aleatoriamente seleccionará qué cantidad devuelve, la mitad de lo recibido o nada. Los participantes no conocen la decisión del jugador B en cada ensayo, pero cuando se alcanza la mitad de la tarea, dos ensayos, los participantes reciben un *feedback* con el total de veces que el jugador B sí les ha devuelto dinero. De este modo se puede decir que cuando un participante está jugando contra una persona, se pone en marcha un proceso de confianza interpersonal en el cual espera que la otra persona le devuelva algo de lo cedido y no actúe con egoísmo. Por el contrario cuando el jugador B sea una máquina, que asigna aleatoriamente su respuesta, estaremos ante un proceso de riesgo puesto que no tenemos elementos para predecir su comportamiento.

#### BIBLIOGRAFÍA

- ALALWAN, A., DWIVEDI, Y. K. y RANA, N. P. (2017). Factors influencing adoption of mobile banking by Jordanian bank customers: Extending UTAUT2 with trust. *International Journal of Information Management*, 37(3), pp. 99-110.
- ALDÁS MANZANO, J., LASSALA NAVARRÉ, C., RUIZMAFÉ, C. y SANZ BLAS, S. (2009). Key drivers of internet banking services use. *Online Information Review*, 33(4), pp. 672-695.
- BAGOZZI, R. P. (2007). The Legacy of the Technology Acceptance Model and a Proposal for a Paradigm Shift. *Journal of the Association for Information Systems*, 8(4), pp. 244-254.
- BART, Y., SHANKAR, V., SULTAN, F. y URBAN, G. L. (2005). Are the drivers y role of online trust the same for all web sites y consumers? A large-scale exploratory empirical study. *Journal of Marketing*, 69, pp. 133-152.
- BAUMGARTNER, T., HEINRICHS, M., VONLANTHEN, A., FISCHBACHER, U. y FEHR, E. (2008). Oxytocin shapes the neural circuitry of trust y trust adaptation in humans. *Neuron*, 58(4), pp. 639-650.
- BENARTZI, S. y THALER, R. (2007). Heuristics y biases in retirement savings behavior. *Journal of Economic Perspectives*, 21, pp. 81-104.
- BISHOP, C. M. (2016). Pattern Recognition and Machine Learning. *Information Science and Statistics*, Vol. 53.
- BREITER, H. C., AHARON, I., KAHNEMAN, D., DALE, A. P. y SHIZGAL, P. (2001). Functional imaging of neural responses to expectancy and experience of monetary gains and losses. *Neuron*, 30, pp. 619-639.
- CAMERER, C., LOEWENSTEIN, G. y PRELEC, D. (2005). Neuroeconomics: how neuroscience can inform economics. *Journal of Economic Literature*, 43, pp. 9-64.
- CAMPBELL, J. Y. (2006). Household finance. *Journal of Finance*, 61, pp. 1553-1604.
- (2016). Restoring rational choice: the challenge of consumer financial regulation. *American Economic Review*, 106, pp. 1-30.
- CAMPBELL, D. y FREI, F. (2010). Cost Structure, Customer Profitability, and Retention Implications of Self-Service Distribution Channels: Evidence from Customer Behavior in an Online Banking Channel. *Management Science*, 56(1), pp. 4-24.
- CARBÓ VALVERDE, S., CUADROS, P. y RODRÍGUEZ, F. (2019). *A machine learning approach to the digitalization of bank customers: evidence from random and causal forests*, <https://www.ssrn.com/abstract=3195286>
- CARBÓ VALVERDE, S., LACOMBA, J., LAGOS, F., RODRÍGUEZ, F. y VERDEJO, J. (2019). *A neurological characterization of financial digitalization*. Mimeo.
- CASALÓ, L. V., FLAVIÁN, C. y GUINALÍU, M. (2007). The role of security, privacy, usability and reputation in the development of online banking. *Online Information Review*, 31(5), pp. 583-603.
- CHENG, T. C. E., LAM, D. Y. C., y YEUNG, A. C. L. (2006). Adoption of Internet Banking: An Empirical Study in Hong Kong. *Decision Support Systems*, 42(3), pp. 1558-1572.
- DAHLBERG, T., GUO, J. y J. ONDRUS (2015). A critical review of mobile payment research. *Electronic Commerce Research and Applications*, 14(5), pp. 265-284.
- DAVIS, F. D., BAGOZZI, R. P. y WARSHAW, P. R. (1989). User Acceptance of Computer Technology: A Comparison of Two Theoretical Models. *Management Science*, 35(8), pp. 982-1003.
- DELGADO, M. R., FRANK, R. H. y PHELPS, E. A. (2005). Perceptions of moral character modulate the neural systems of reward during the trust game. *Nature Neuroscience*, 8(11), pp. 1611-1618.
- DIMOKA, A. (2010). What does the brain tell us about trust y distrust? Evidence from a functional neuroimaging study. *MIS Quarterly*, 34(2), pp. 373-396.
- ELLIOTT, R., FRISTON, K. J. y DOLAN, D. J. (2000). Dissociable neural responses in human reward systems. *The Journal of Neuroscience*, 20(16), pp. 6159-6165.
- FARERI, D. S., CHANG, L. J. y DELGADO, M. R. (2012). Effects of direct social experience on trust decisions and neural reward circuitry. *Frontiers in Neuroscience*, 6(148), pp. 1-17.
- FRYDMAN, C. y CAMERER, C. F. (2016). The psychology y neuroscience of financial decision making. *Trends in Cognitive Sciences*, 20, pp. 661-675.
- GLIMCHER, P. (2002). Decisions, decisions, decisions: choosing a biological science of choice. *Neuron*, 36, pp. 323-332.
- GLIMCHER, P. W. y FEHR, E. (2013). *Neuroeconomics: Decision Making y the Brain*. Elsevier Science, 2nd edition.
- HÄUSLER, A. N., KUHNEN, C. M., RUDOLF, S. y WEBER, B. (2018). Preferences and beliefs about financial risk taking mediate the association between anterior insula activation and self-reported real-life stock trading. *Nature –Scientific Reports*, 8 (11207), pp. 1-13.
- HERNÁNDEZ-MURILLO, R., LLOBET, G., y FUENTES, R. (2010). Strategic online banking adoption. *Journal of Banking and Finance*, 34(7), pp. 1650-1663.



- HOEHLE, H., SCORNAVACCA, E. y HUFF, S. (2012). Three decades of research on consumer adoption and utilization of electronic banking channels: A literature analysis. *Decision Support Systems*, 54(1), pp. 122-132.
- HUANG, J., MAKUJU, E., NEWELL, S. y GALLIERS, R. D. (2003). Opportunities to learn from «failure» with electronic commerce: A case study of electronic banking. *Journal of Information Technology*, 18(1), pp. 17-26.
- HUBERT, M., FLORACK, A., LINZMAIER, M. y KENNING, P. (2013). Neural correlates of impulsive buying tendencies during perception of product packaging. *Psychology & Marketing*, 30(10), pp. 861-873.
- HUETTEL, S. A., STOWE, C. J., GORDON, E. M., WARNER B. T. y PLATT, M. L. (2006). Neural signatures of economic preferences for risk y ambiguity. *Neuron*, 49, pp. 766-775.
- JARUWACHIRATHANAKUL, B. y FINK, D. (2005). Internet banking adoption strategies for a developing country: the case of Thailand. *Internet Research*, 15(3), pp. 295-311.
- KESHARWANI, A. (2019). Do (how) digital natives adopt a new technology differently than digital immigrants? A longitudinal study. *Information and Management* (August 2016), pp. 103-170.
- KEYS, B. J., POPE, D. G. y POPEC, J. C. (2016). Failure to refinance. *Journal of Financial Economics*, 122, pp. 482-499.
- KING-CASAS, B., TOMLIN, D., ANEN, C., CAMERER, C. F., QUARTZ, S. R. y MONTAGUE, P. R. (2005). Getting to know you: reputation y trust in a two-person economic exchange. *Science*, 308(5718), pp. 78-83.
- KNUTSON, B. y BOSSAERTS, P. (2007). Neural Antecedents of Financial Decisions. *Journal of Neuroscience*, 27, pp. 8174-8177.
- KNUTSON, B., FONG, G., BENNETT, S., ADAMS, C. y HOMMER, D. (2003). A region of mesial prefrontal cortex tracks monetarily rewarding outcomes: characterization with rapid event-related fMRI. *Neuroimage*, 18, pp. 263-272.
- KRUEGER, F., MCCABE, K., MOLL, J., KRIEGESKORTE, N., ZAHN, R. y STRENIOK, M. (2007). Neural correlates of trust. *Proceedings of the National Academy of Sciences of the United States of America*, 104(50), pp. 20084-20089.
- KUHNNEN, C. M. y KNUTSON, B. (2005). The neural basis of financial risk taking. *Neuron*, 47(5), pp. 763-770.
- (2011). The Influence of Affect on Beliefs, Preferences, y Financial Decisions. *Journal of Financial Quantitative Analysis*, 46, pp. 605-626.
- LAUKKANEN, T. (2016). Consumer adoption versus rejection decisions in seemingly similar service innovations: The case of the Internet and mobile banking. *Journal of Business Research*, 69(7), pp. 2432-2439.
- LEE, M. C. (2009). Factors influencing the adoption of internet banking: An integration of TAM and TPB with perceived risk and perceived benefit. *Electronic Commerce Research and Applications*, 8(3), pp. 130-141.
- LU, M. T., TZENG, G. H., CHENG, H. y HSU, C. C. (2015). Exploring mobile banking services for user behavior in intention adoption: using new hybrid MADM model. *Service Business*, 9(3), pp. 541-565.
- LOUREIRO, S., RÜDIGER KAUFMANN, H. y S. RABINO (2014). Intentions to use and recommend to others. *Online Information Review*, 38(2), pp. 186-208.
- MCKENNA, B., TUUNANEN, T. y GARDNER, L. (2013). Consumers' adoption of information services. *Information and Management*, 50(5), pp. 248-257.
- O'DOHERTY, J., DAYAN, P., SCHULTZ, J., DEICHMANN, R., FRISTON, K. y DOLAN, R. J. (2004). Dissociable roles of ventral and dorsal striatum in instrumental conditioning. *Science*, 16(304) (5669), pp. 452-454.
- PREUSCHOFF, K., BOSSAERTS, P. y QUARTZ, S. R. (2006). Neural differentiation of expected reward y risk in human subcortical structures. *Neuron*, 51(3), pp. 381-390.
- POUSTTCHI, K. y DEHNERT, M. (2018). Exploring the digitalization impact on consumer decision-making in retail banking. *Electronic Markets*, 28(3), pp. 265-286.
- RIEDL, R., MOHR, P., KENNING, P., DAVIS, F. y HECKEREN, H. (2014). Trusting humans y avatars: abrain imaging study based on evolution theory. *Journal of Management Information Systems*, 30(4), pp. 83-114.
- RUDORF, S., PREUSCHOFF, K. y WEBER, B. (2012). Neural Correlates of Anticipation Risk Reflect Risk Preferences. *The Journal of Neuroscience*, 32(47), pp. 16683-16692.
- SONNEMANN, U., CAMERER, C. F., FOX, C. R. y LANGER, T. (2013). How psychological framing affects economic market prices in the lab and field. *Proceedings of the National Academy of Sciences U.S.A.*, 110(29), pp. 11779-11784.
- SUSANTO, A., CHANG, Y. y HA, Y. (2016). Determinants of continuance intention to use the smartphone banking services. *Industrial Management & Data Systems*, 116(3), pp. 508-525.
- SZOPI SKI, T. S. (2016). Factors affecting the adoption of online banking in Poland. *Journal of Business Research*, 69(11), pp. 4763-4768.
- TAM, C. y OLIVEIRA, T. (2019). Does culture influence m-banking use and individual performance? *Information and Management*, 56(3), pp. 356-363.
- WANG, Y. D. y EMURIAN, H. H. (2005). An overview of online trust: concepts, elements, y implications. *Computers in Human Behavior*, 21(1), pp. 105-125.
- YOON, H. S. y BARKER, L. M. (2013). Development of a quantitative model of the impact of customers' personality and perceptions on Internet banking use. *Computers in Human Behavior*, 29(3), pp. 1133-1141.
- YUSUF DAUDA, S. y J. LEE (2015). Technology adoption: A conjoint analysis of consumers' preference on future online banking services. *Information Systems*, 53, pp. 1-15.



## Resumen (\*\*)

El presente artículo examina la evolución del crédito *peer-to-peer* (P2P) *online* durante la última década. Comienza con una exhaustiva revisión de la investigación relevante publicada en ocho de las principales revistas especializadas en finanzas, contabilidad y dirección de empresas entre 2010 y 2019. Las claves y conclusiones obtenidas a partir de la literatura se emplean a continuación para analizar la industria del crédito de mercado (*marketplace lending*) en un país, China, cuyo mercado P2P supera en tamaño al de todo el resto del mundo junto. Paradójicamente, se da la circunstancia de que cerca de dos terceras partes de las plataformas de crédito P2P *online* en China han quebrado. La evidencia empírica resultante de datos operativos mensuales de 735 plataformas crediticias y de los datos a nivel de transacción procedentes de una prominente plataforma (Renrendai) confirma muchas de las predicciones teóricas. También se apuntan algunas observaciones con el fin de orientar la investigación futura sobre el crédito P2P.

*Palabras clave:* crédito *peer-to-peer*, China, quiebra de plataforma, *fintech*.

## Abstract

This article traces the evolution of online peer-to-peer (P2P) lending in the past decade. It starts with a comprehensive review of related research published in eight leading journals in finance, accounting and management from 2010 to 2019. Insights derived from the literature are then used to analyze the marketplace lending industry in one country, China, where the size of the P2P market is larger than that of the rest of the world combined. Ironically, it is also true that, in China, around two-third of the online P2P lending platforms have failed. Empirical evidence from monthly operating data of 735 lending platforms and transaction level data from one prominent platform (Renrendai) confirms many theoretical predictions. We also provide observations to help guide future research in P2P lending.

*Keywords:* peer-to-peer lending, China, platform failure, *fintech*.

*JEL classification:* G21, G23, L5, O31.

# VISIONES ACTUALES SOBRE EL CRÉDITO *PEER-TO-PEER* ONLINE: LA EVIDENCIA DE CHINA

Iftekhar HASAN (\*)

Universidad de Fordham

Qing HE

Universidad Renmin de China, Beijing, China

Haitian LU

Universidad Politécnica de Hong Kong

## I. INTRODUCCIÓN

EL término *finTech* designa la aplicación de las nuevas tecnologías al diseño y la oferta de productos y servicios financieros (Goldstein, Jiang y Karolyi, 2019). Una de las principales invenciones surgidas con ese empleo de la tecnología en el sector financiero en la última década ha sido el crédito de mercado (*marketplace lending*) *online* (OML, por sus siglas en inglés). El OML consiste en aplicar datos y tecnología para hacer posible el préstamo *peer-to-peer* (P2P, entre iguales) a través de un mercado o portal *online* sin intervención de intermediarios financieros. En el modelo OML, los prestamistas pujan sobre propuestas de préstamos (*listings*) no respaldados por activos de garantía publicadas por prestatarios anónimos. Basándose en una pléyade de información tanto estandarizada como no estandarizada, los prestamistas toman decisiones sobre si pujar, y cuánto, por una propuesta de préstamo concreta. El préstamo queda materializado cuando el importe solicitado es suscrito en su totalidad.

El rápido desarrollo del OML desde la década de 2010 se debe a una serie de factores exógenos, entre los que cabe citar:

los avances tecnológicos, que han abaratado enormemente los costes de computación, el almacenamiento y los dispositivos; el auge del crédito al consumo y a pequeñas empresas; y las consecuencias de la crisis financiera, que llevó a reforzar los requisitos regulatorios a los bancos tradicionales. En Estados Unidos, una de las mayores plataformas de crédito P2P, Lending Club, ha captado más de cuatro millones de clientes facilitando préstamos por un importe total superior a 50.000 millones de dólares desde 2007. Otra plataforma de crédito P2P, Prosper Marketplace, ha ayudado a más 940.000 particulares a financiar préstamos de más de 15.000 millones de dólares desde 2005. Un informe de Transparency Market Research (TMR) predice que el mercado mundial de crédito *peer-to-peer* crecerá a una tasa anual compuesta del 48,2 por 100 entre 2016 y 2024, hasta alcanzar un tamaño de mercado de 897.850 millones de dólares para finales de 2014 (1).

Conviene señalar que, entre los principales mercados de crédito P2P, China por sí sola supera al resto de sectores P2P mundiales en conjunto, con un total de préstamos en circulación de 1,49 billones de renminbis (217.960 millones de dólares) en 2018. En

2015, el sector, prácticamente exento de regulación por entonces, registró su máximo, contabilizándose en torno a 3.500 negocios de crédito P2P en todo el mundo (2). No obstante, los datos de Wangdaizhijia, el principal instituto de seguimiento y estudios de mercado de OML de China, indican que, hasta 2019, cerca de dos terceras partes de las plataformas OML han quebrado. ¿Qué explica esta sorprendente evolución? ¿Hasta qué punto puede la investigación académica arrojar luz sobre el crédito P2P a los interesados en este sector en clara expansión? Y más importante, ¿está sustentada sobre datos nuestra comprensión del funcionamiento de este mercado?

Con estas cuestiones en mente, el presente artículo comienza con una «revisión estructurada de la literatura» de los trabajos de investigación sobre P2P publicados en ocho destacadas revistas de finanzas, contabilidad y dirección de empresas durante el período entre 2010 y 2019. Una revisión estructurada de la literatura «es un método de estudio de un corpus de investigaciones académicas a fin de ahondar en su conocimiento, formular reflexiones críticas, y plantear vías de investigación futuras y preguntas para el análisis» (Massaro, Dumay y Guthrie, 2016: 767). Este ejercicio revela que se publicaron trece artículos sobre crédito *peer-to-peer* en los siguientes medios: *Review of Financial Studies* [3], *The Accounting Review* [1] y *Management Science* [9]. Analizamos sus perspectivas, metodologías y contribuciones clave con el objetivo de generar ideas, plantear críticas y obtener una redefinición transformadora del sector de crédito P2P, los tres resultados

que debe perseguir cualquier investigación crítica sobre gestión enunciados por Alvensson y Deetz (2000).

A continuación, utilizamos estas ideas para analizar el mercado P2P de China. En primer lugar, describimos los mecanismos de mercado y los factores intrínsecos/extrínsecos que explican la evolución del sector de crédito P2P de China. Para el análisis de este mercado, utilizamos un conjunto de datos privados que comprenden 735 plataformas únicas y 9.556 observaciones plataforma-mes con datos para todas las variables propuestas para el período 2011 a 2015. De las 735 plataformas, 476 quebraron en distintas fases de la etapa muestral. Si bien nuestra muestra no cubre todas las plataformas existentes, es con mucho la representación más exhaustiva y completa de datos a nivel de plataforma sobre el mercado OML de China. Nuestro objetivo es comparar sistemáticamente las características de plataformas «fallidas» y «en normal funcionamiento» y realizar inferencias sobre los factores con capacidad de predecir la quiebra de una plataforma.

La siguiente sección del artículo se apoya en datos de Renrendai (RRD), una de las mayores plataformas de crédito *peer-to-peer* de China. Desde su lanzamiento oficial en septiembre de 2010, RRD ha captado más de 2,5 millones de socios y a 31 de diciembre de 2015 había contribuido a intermediar 13.000 millones de renminbis (2.000 millones de dólares) en préstamos. Estos datos nos permiten observar la información detallada por prestatario, características de la operación propuesta (*listing*) y préstamo, así como de qué forma pujan los

prestamistas. Utilizamos estos datos para llevar a cabo consultas a modo de test respecto a la literatura empírica, que hasta ese momento solo se fijaba en el mercado estadounidense.

El resto del artículo se organiza como sigue: la sección segunda resume la literatura existente sobre el crédito P2P. La tercera sección introduce el mecanismo del crédito de mercado *online* (*online marketplace lending*, OML) y el contexto institucional en China. La sección cuarta presenta un análisis empírico de 735 plataformas OML (tanto fallidas como en funcionamiento) en China para arrojar luz sobre las causas de que una plataforma quiebre. La quinta sección presenta un resumen estadístico y análisis empírico piloto basado en una plataforma: RRD. En la sección sexta se presentan las conclusiones.

## II. REVISIÓN DE LA LITERATURA

### 1. Metodología de selección de artículos y panorámica

Nuestra revisión de la literatura abarca trece artículos centrados en el fenómeno del crédito *peer-to-peer* que fueron publicados en destacadas revistas del mundo de las finanzas, la contabilidad y la dirección de empresas. Para mantener el alcance de nuestra revisión de la literatura dentro de unos límites manejables, excluimos los documentos de trabajo (*working papers*), y nos centramos en las ocho principales revistas de finanzas, contabilidad y dirección de empresas listadas en la web «Top 100 Business School Research Rankings» de la Universidad de Texas en Dallas

CUADRO N.º 1

ARTÍCULOS PUBLICADOS SOBRE CRÉDITO *PEER-TO-PEER* (2010-2019)

| REFERENCIA               | REVISTA    | AÑO  | FUENTE PRINCIPAL         | ENFOQUE GEOGRÁFICO | METODOLOGÍA                 |
|--------------------------|------------|------|--------------------------|--------------------|-----------------------------|
| Duarte <i>et al.</i>     | <i>RFS</i> | 2012 | Propser.com              | EE.UU.             | Análisis empírico           |
| Zhang y Liu              | <i>MS</i>  | 2012 | Propser.com              | EE.UU.             | Análisis empírico           |
| Michels                  | <i>TAR</i> | 2012 | Propser.com              | EE.UU.             | Análisis empírico           |
| Lin <i>et al.</i>        | <i>MS</i>  | 2013 | Propser.com              | EE.UU.             | Análisis empírico           |
| Lin y Viswanathan        | <i>MS</i>  | 2016 | Propser.com              | EE.UU.             | Análisis empírico           |
| Iyer <i>et al.</i>       | <i>MS</i>  | 2016 | Propser.com              | EE.UU.             | Análisis empírico           |
| Paravisini <i>et al.</i> | <i>MS</i>  | 2017 | Lending Club             | EE.UU.             | Análisis teórico y empírico |
| Hildebrand <i>et al.</i> | <i>MS</i>  | 2017 | Propser.com              | EE.UU.             | Análisis empírico           |
| Wei y Lin                | <i>MS</i>  | 2017 | Propser.com              | EE.UU.             | Análisis teórico y empírico |
| Butler <i>et al.</i>     | <i>MS</i>  | 2017 | Propser.com              | EE.UU.             | Análisis empírico           |
| Vallee y Zeng            | <i>RFS</i> | 2019 | Lending Robot            | EE.UU.             | Análisis teórico y empírico |
| Tang                     | <i>RFS</i> | 2019 | Lending Club             | EE.UU.             | Análisis teórico y empírico |
| Du <i>et al.</i>         | <i>MS</i>  | 2019 | A China Lending Platform | China              | Análisis empírico           |

(UTD). Estas revistas incluyen: *Journal of Finance (JF)*, *Journal of Financial Economics (JFE)*, *Review of Financial Studies (RFS)*, *Accounting Review (TAR)*, *Journal of Accounting and Economics (JAE)*, *Journal of Accounting Research (JAR)*, *Management Science (MS)* e *Information System Research (ISR)*.

A los efectos de identificar los artículos relacionados con el campo del P2P, realizamos una primera criba por dimensión temporal, restringiéndola a aquellos artículos aparecidos en alguna de las revistas citadas en la década comprendida entre 2010 y 2019. Este enfoque es lógico, ya que las primeras plataformas de crédito P2P, por ejemplo, Prosper Marketplace y LendingClub, se fundaron a finales de la década de 2000 y sus datos no estuvieron disponibles para los investigadores hasta la siguiente década. En primer lugar realizamos una búsqueda por el título del artículo y determinadas palabras clave, requiriendo que contengan en

todo o en parte los términos «crédito *peer-to-peer*», «crédito entre particulares», «P2P», «*crowdfunding* de deuda» o «crédito de mercado» (*marketplace lending*). En el caso de que el título de un artículo no contenga estas palabras clave, leemos el resumen atentamente para asegurarnos de que guarden relación con el crédito *peer-to-peer*.

Este ejercicio genera trece artículos. El cuadro n.º 1 resume sus detalles.

El cuadro n.º 1 muestra que, en tanto que un campo floreciente de la nueva economía, el sector P2P ha sido objeto de atención académica en las revistas de más tirada de la dirección de empresas, finanzas y contabilidad. *Management Science* publicó el mayor número [9] de artículos sobre el crédito P2P, seguido del *Review of Financial Studies*, que publicó tres [3] artículos. Hay que precisar que durante el año 2019 el *RFS* publicó un volumen especial sobre el fenómeno *fin-*

*tech* tras un protocolo editorial de selección de manuscritos a lo largo de dos años (véase el artículo editorial de Goldstein, Jiang y Karolyi, 2019). Este volumen especial contiene dos artículos sobre crédito *peer-to-peer* de las 47 propuestas enviadas. Uno de los artículos publicados en el *Accounting Review* (Michels, 2012) reviste interés, al utilizar análisis textual sobre las *disclosures* realizadas en la plataforma P2P Prosper.com.

Una ventaja de la investigación sobre el crédito *peer-to-peer* es la amplitud del conjunto de datos disponibles. En Estados Unidos, dos de las principales plataformas de crédito *peer-to-peer*, Prosper Marketplace y Lending Club, dominan el mercado. Además, ambas plataformas publican estadísticas de rentabilidad y datos de mercado en su página web, disponibles para análisis. En consecuencia, doce de los trece artículos publicados tienen EE.UU. como su foco geográfico, y de ellos nueve utilizan datos

procedentes de Prosper.com, mientras que otros dos utilizan datos de Lending Club. En cuanto a la metodología de estudio empleada, todos los artículos revisados son empíricos, y cuatro de ellos combinan tanto el análisis teórico como el empírico.

## 2. Líneas de investigación

Un aspecto importante reside en las líneas de investigación abordadas por estos artículos. Nuestra revisión revela que, en general, pueden distinguirse tres grandes líneas de investigación según su enfoque: 1) comprensión del comportamiento de los inversores en el crédito *peer-to-peer*; 2) incentivos y diseño del mecanismo en las plataformas *peer-to-peer*; y 3) interrelación existente entre el crédito P2P y la financiación bancaria.

### 2.1. Comprensión del comportamiento de los inversores en el crédito *peer-to-peer*

En el *crowdfunding* de deuda, los prestamistas pujan por propuestas de préstamo (*listings*) no respaldadas por activos de garantía publicadas por prestatarios anónimos. Partiendo de una pléyade de información tanto estandarizada como no estandarizada, los prestamistas toman decisiones sobre *si* y *cuánto* pujar por una propuesta de préstamo concreta. El préstamo queda materializado cuando el importe solicitado es suscrito en su totalidad; de lo contrario, se considera que la propuesta no ha prosperado. La pregunta natural que cabe hacerse es, en un entorno anónimo, ¿cómo evalúan los prestamistas individuales a los prestatarios?

Una perspectiva útil es considerar la teoría de la selección adversa. Akerlof (1970) muestra cómo la selección adversa entre vendedores y compradores en el mercado de coches de segunda mano provoca que el mercado fracase. En el mercado de crédito, los deudores conocen cuál es su capacidad de pago y su disposición a devolver la deuda mejor que los acreedores. La asimetría de información se ve magnificada en un entorno *online*, donde no existe interacción cara a cara entre deudor y acreedor. Si los prestamistas no tienen forma de distinguir a los prestatarios de alta calidad de los de baja calidad, solo estarán dispuestos a pujar a tipos de interés «medios». Esto beneficia a los prestatarios de baja calidad, provocando que los de alta calidad salgan del mercado. Sabedores de que solo quedan en el mercado prestatarios de baja calidad, los prestamistas, aversos al riesgo, también se retirarán, y el mercado fracasará.

Por tanto, la clave para evitar que el OML se convierta en un «mercado de cacharros» es proporcionar a los prestamistas información útil que ayude a «señalar» la calidad del prestatario. En una plataforma P2P tipo, la información «dura» (factual) disponible para los prestamistas suele incluir la edad del prestatario, el sexo, rango de ingresos, nivel de educación, experiencia laboral, si tiene una vivienda en propiedad, su historial de crédito en la plataforma, y el grado de solvencia asignado por la plataforma, etc. La información «blanda», que incluye información difícil de cuantificar y otros datos que sí son cuantificables pero no suelen ser utilizados por los bancos, consiste en domicilio habitual, fotografía, red de

amistades en la plataforma, y declaraciones textuales.

Siguiendo este modo de proceder, varios artículos estudian la utilidad de la información tanto «dura» como «blanda» para predecir el éxito en la financiación, el precio y la probabilidad de impago. Toda esta literatura concluye que la información «dura» tradicional, y en especial la calificación crediticia asignada por la plataforma en base a su propio algoritmo de evaluación, es un indicador importante. Asimismo importante es que los estudios revelan que cuando los prestamistas evalúan la credibilidad de los prestatarios, tienden a tomar sus decisiones de concesión de crédito sobre la base de la información «blanda».

Partiendo de 20.000 propuestas (*listings*) seleccionadas aleatoriamente y 6.500 préstamos de Prosper.com entre mayo de 2006 y enero de 2008, Duarte *et al.* (2012) estudian si la solvencia del deudor individual juzgada a partir de su apariencia física afecta a las decisiones de crédito por parte de los inversores. Preguntan, en primer lugar, a veinticinco profesionales independientes en MTurk que juzguen y califiquen la solvencia de los deudores y su disposición a reembolsar la deuda a partir de una fotografía del prestatario, y a continuación extraen el promedio de las puntuaciones otorgadas por todos estos profesionales. El estudio empírico demuestra que las personas juzgadas más solventes tendrían mayores probabilidades de obtener un préstamo y pagar un tipo de interés más reducido. Además, los deudores juzgados como solventes tienden a presentar mejores *scores* crediticios y tasas de impago más bajas. Aun cuando los deudores juzgados



como solventes tienden a pagar tipos de interés más reducidos, los prestamistas siguen aplicando tipos de interés elevados, lo que sugiere que en su proceso de decisión no incorporan plenamente la menor probabilidad de impago de los deudores juzgados solventes, y que sigue existiendo cierta anomalía de precios en el tipo de interés.

Inspirándose en la literatura sobre selección adversa y señalización, Lin *et al.* (2013) argumentan que las amistades pueden actuar como señalizador de la calidad crediticia en un mercado de crédito *online*. Utilizando una muestra de *listings* de préstamos en Prosper.com entre enero de 2007 y mayo de 2008, los autores comprueban que las amistades podrían aumentar la probabilidad de que una propuesta llegue a buen fin y reciba un tipo de interés más bajo. Asimismo, las amistades están asociadas a unas tasas de impago *ex post* más bajas. Y este efecto es más pronunciado cuando la jerarquía de amistades, medida por los cargos desempeñados y la identidad de dichas amistades, es alta.

Iyer *et al.* (2016) también aportan evidencia empírica de que la información financiera tanto estándar como «blanda» o no estándar ayuda a inferir la calidad de los pequeños deudores. Utilizando un conjunto de datos de Prosper.com entre febrero de 2007 y octubre de 2008, que contiene todas las variables sobre información de crédito que aparecen en un *listing* de préstamo de un deudor y el texto de dicha propuesta, los autores demuestran, utilizando fuentes de información no estándar o «blanda», que los prestamistas individuales son capaces de predecir la probabilidad de impago de los deu-

dores con mayor precisión que el *score* crediticio exacto asignado a cada deudor.

Michels (2012) estudia una clase de información «blanda», la divulgación de datos «no verificables» del deudor. Utilizando préstamos no garantizados a tres años procedentes de Prosper.com, concluye que la divulgación adicional de un dato no verificable está asociada con una reducción de 1,27 puntos porcentuales del tipo de interés y un aumento del 8 por 100 de la actividad de pujas. Y el efecto de estas divulgaciones es más fuerte para deudores con un perfil crediticio comparativamente más débil. Además, la divulgación de datos no verificables está asociada negativamente a los impagos futuros en los préstamos.

Una diferencia clave entre el crédito *peer-to-peer* y el crédito bancario consiste en que los prestamistas individuales, que no son expertos, tienden a utilizar su categorización, e incluso estereotipado, para minimizar los costosos procesos mentales (Gilbert y Hixon, 1991). Por ejemplo, Lin y Viswanathan (2015) confirman la existencia de un sesgo nacional (*home bias*) en el mercado de préstamos *online*. Utilizando análisis de datos diarios de transacciones en Prosper.com anteriores a 2008, encuentran que los prestamistas tienden a invertir en prestatarios de su propio estado. A efectos de identificación, designan un cuasiexperimento a nivel de *listing* que explota el cambio de residencia de los prestatarios a otros estados como variaciones exógenas, y constatan que, tras el cambio, el número de pujas procedentes del estado de origen disminuye, mientras que las procedentes del estado de destino aumentan.

Herzenstein, Dholakia y Andrews (2011) documentan evidencia de «efecto rebaño» entre los prestamistas de Prosper, en virtud del cual los *listings* de prestatarios que han atraído un mayor número de prestamistas tienen más probabilidades de captar nueva financiación. Zhang y Liu (2012) distinguen además entre comportamientos «rebaño» racionales e irracionales. Los autores documentan que en lugar de imitar pasivamente a sus pares (rebaño de tipo irracional), los prestamistas aprenden activamente por observación (rebaño de tipo racional); infieren la solvencia de los prestamistas observando las decisiones de crédito de sus pares, y utilizan las características públicamente observables para moderar sus inferencias.

Paravisini, Rappoport y Ravina (2017) estiman la aversión al riesgo a partir de las decisiones financieras de los inversores y la elasticidad a la riqueza utilizando datos procedentes del Lending Club. Dado que el mismo individuo invierte de manera repetida, los autores construyen un conjunto de datos de panel que utilizan para desentrañar la heterogeneidad en las actitudes hacia el riesgo de los inversores. Encuentran que los inversores con mayores niveles de riqueza muestran, de media, mayor aversión al riesgo, y que el grado de aversión al riesgo de los inversores aumenta tras producirse un *shock* negativo de riqueza inmobiliaria.

## 2.2. Incentivos y diseño de mecanismo en las plataformas *peer-to-peer*

Un segundo grupo de literatura se centra en los incentivos y



el diseño de mecanismos en las plataformas de crédito *peer-to-peer*. El grueso de los ingresos de negocio de las plataformas OML procede de las «comisiones de servicio» basadas en el volumen por cada préstamo que se origina con éxito. A diferencia de los bancos, las plataformas *peer-to-peer* actúan en una triple calidad de mercado (*marketplace*), agencia de selección y emparejador de la oferta y la demanda. Las plataformas no suelen asumir riesgo de crédito del prestatario, pero pueden cobrar comisiones cada vez que se origina un nuevo préstamo. La comisión de servicio cobrada varía en función de los *ratings* de crédito del prestatario. De ello se deduce que cada plataforma P2P tiene un incentivo para maximizar el volumen de préstamos facilitados, y para utilizar el diseño del mecanismo como herramienta para maximizar su propio beneficio. Desde su creación, tanto Prosper Marketplace como Lending Club están aprendiendo del mercado y experimentando con diferentes diseños de mecanismo. Estas alteraciones en el mecanismo ofrecen oportunidades a los investigadores para comprender los aspectos económicos subyacentes al crédito *peer-to-peer*.

Cuatro artículos entran en esta categoría. Wei y Lin (2017) comparan dos mecanismos de mercado, a saber, un mecanismo *basado en subasta* y el mecanismo de *precios publicados* en el crédito de mercado. En las subastas, la «multitud» determina el «precio» (tipo de interés) de la transacción mediante un proceso de subasta. En el sistema de precios publicados, la plataforma determina el tipo de interés sobre la base de su propia «graduación» del prestatario. Mediante la construcción

de un modelo de mecanismos de mercado ligados a la teoría de juegos, los autores predicen que el mecanismo de los precios publicados beneficia tanto a prestatarios como a prestamistas gracias a un despliegue más rápido de los fondos, pero lleva a que los prestatarios paguen tipos de interés más altos, aumentando de ese modo el riesgo de impago en el préstamo. A partir de los datos de *listings* de préstamos de Prosper.com entre 2010 y 2011, y utilizando como evento exógeno un único cambio de régimen desde el sistema de subasta al de precios publicados el 20 de diciembre de 2010, testan las predicciones anteriormente citadas y obtienen resultados consistentes. Al examinar el cambio experimentado en el bienestar social, su estudio demuestra que los mecanismos de precios publicados reducen el bienestar social global aun cuando podrían aumentar el excedente de la plataforma.

Hildebrand, Puri y Rocholl (2017) explotan un experimento sobre diseño de mecanismos en Prosper, consistente en remunerar una vez a los «líderes de grupo» en el proceso de pujas con una comisión de originación. En particular, analizan las pujas realizadas por los líderes de grupo en presencia de comisiones de originación y concluyen que estas pujas son (equivocadamente) percibidas como una señal de buena calidad del préstamo, y el resultado son unos tipos de interés más bajos. Pero estos préstamos presentan tasas de impago más altas. A largo plazo, ello daña la reputación de la plataforma. Congruente con esta conjetura, los autores encuentran que esos incentivos adversos solo son superados cuando existe suficiente «skin in

the game» (se juegan su patrimonio) y no existen comisiones de originación.

El artículo de Vallee y Zeng (2019) estudia de qué modo las plataformas pueden maximizar su utilidad mediante la provisión de información estratégica. A diferencia del crédito tradicional donde los bancos son el único proveedor de información, argumentan que el crédito P2P constituye un nuevo paradigma en el que tanto las plataformas P2P como los inversores producen información conjuntamente. En este nuevo paradigma, la producción de mayor información desde la plataforma hacia unos inversores sofisticados podría incrementar la selección adversa y dañar el volumen de contratación de la plataforma. Por tanto, para maximizar el volumen de contratación, la plataforma necesita encontrar un compromiso entre los mejores resultados de selección (*screening*) y un problema de selección adversa.

Construyendo un modelo teórico, Vallee y Zeng (2019) demuestran que la estrategia óptima para la plataforma es proporcionar niveles intermedios de intensidad de *prescreening* por la plataforma y provisión de información a los inversores. Para testar este modelo, utilizan datos procedentes de Lending Robot entre enero de 2014 y febrero de 2017, y concluyen que los inversores sofisticados criban más activamente los préstamos y tienen una mejor rentabilidad en su inversión. No obstante, este superior comportamiento disminuye conforme aumenta el coste de *screening* (aproximado por el evento de que Lending Club redujera la información sobre las características de los prestatarios a partir del 7 de noviembre de

2014). Estos resultados son consistentes con el hecho de que las plataformas gestionen la selección adversa y produzcan un nivel intermedio de información.

Otro reto que afrontan las plataformas es cómo incrementar la disposición de los prestatarios a pagar. Du *et al.* (2019) implementan varios mecanismos conductuales en un experimento de campo, en condiciones naturales, para mitigar los problemas de riesgo moral en el crédito P2P. Este estudio se lleva a cabo en una página web de crédito P2P de tamaño mediano en China que envía mensajes recordatorios antes de las fechas programadas de amortización de los préstamos. Para integrar los mecanismos conductuales en los mensajes recordatorios, los autores diseñan un experimento de campo en el que una dimensión es la variación en el contenido del mensaje (tono neutral, expectativas positivas o consecuencias adversas) y la otra dimensión es si la identidad del prestamista es revelada. La plataforma enviará el primer mensaje inmediatamente después de la aprobación del préstamo, el segundo, un día antes de la primera fecha de pago, y el último, al cabo de treinta días contados a partir de la fecha de pago final si por entonces el préstamo sigue impagado. Utilizando préstamos aprobados durante el período del 1 al 31 de mayo de 2016, el estudio muestra que los mensajes de texto de recordatorio con una expectativa positiva incrementan la probabilidad de reembolso de los prestatarios a corto y largo plazo, mientras que los recordatorios que hacen hincapié en las consecuencias adversas de la falta de pago de los préstamos tienen un impacto a corto plazo en la probabilidad de reembolso.

### 2.3. La interrelación entre el crédito P2P y la financiación bancaria

El crédito P2P proporciona financiación *online* sin respaldo de activos de garantía, de manera que se solapa en parte con la actividad bancaria. Una cuestión importante es si el crédito P2P funciona como sustituto de los bancos o, más bien, como complemento. Esta pregunta es legítima, ya que si el crédito P2P, en tanto que nuevo modelo de negocio basado en la tecnología, funciona como «sustituto» de los servicios tradicionales de los bancos, los bancos deberían estar preocupados por la pérdida de clientes a manos de las compañías tecnológicas. Pero si el sector del crédito P2P presta servicio principalmente a un grupo de prestatarios no bancarizados o a los que las entidades de crédito tradicionales han denegado la financiación, entonces serviría como «complemento» del sistema bancario para fomentar la inclusión financiera.

Para explorar la interrelación entre la banca y el crédito P2P, Tang (2019) diseña un marco conceptual para predecir cómo afectaría un *shock* negativo en la concesión de crédito bancario a la cantidad y composición de los préstamos P2P. Según las predicciones, si las plataformas P2P y los bancos fueran sustitutos perfectos, el *shock* negativo en la concesión de crédito por los bancos incrementaría el volumen de crédito P2P y disminuiría la calidad media de los prestamistas P2P. Si su relación fuese perfectamente complementaria, una reducción de la oferta de crédito bancario conduciría a un incremento tanto del volumen prestado como de la calidad media

de los prestatarios. Y en el caso intermedio, un *shock* negativo incrementaría el volumen prestado. Para testar empíricamente estas predicciones, Tang utiliza el método de «diferencias en diferencias», donde los condados que se ven sujetos a la regulación de FAS 166/167 en 2010 constituyen el grupo de tratamiento, y utiliza datos de operaciones P2P del Lending Club entre 2009 y 2012 para construir variables a nivel de condado. Tang concluye que el crédito P2P se expande en aquellos mercados donde la oferta del crédito bancario sufre restricciones, y podría funcionar como sustituto de la banca cuando los prestatarios bancarios de baja calidad migran a las plataformas P2P. Además, los prestamistas P2P también complementan a los bancos al proporcionar préstamos de montante reducido.

Butler, Cornaggia y Gurun (2017) examinan la misma cuestión, pero desde un prisma diferente. Basándose en datos de *listings* de Prosper entre abril de 2008 y diciembre de 2010, y utilizando los depósitos bancarios a nivel de condado y el número de sucursales bancarias aseguradas por el FDIC (Federal Deposit Insurance Corporation) dentro de un condado como aproximación del acceso a la financiación bancaria, los autores muestran que los prestatarios que residen en áreas con buen acceso a la financiación bancaria recurren a préstamos P2P con tipos de interés más bajos. Este efecto es más fuerte en el caso de los prestatarios con baja solvencia y aquellos que demandan préstamos con montantes reducidos. Su evidencia respalda la existencia de una relación «sustitutiva» entre el sector de la banca y el sector del crédito P2P.

### III. EL SECTOR DEL CRÉDITO PEER-TO-PEER EN CHINA

#### 1. Entorno institucional

China es la mayor economía entre los mercados emergentes con mercados financieros en desarrollo. Los bancos dominan el sistema financiero chino, aportando tres quintas partes del crédito total al sector privado (Elliot, Kroeber y Yu, 2015). El sistema bancario en China está concentrado, y cinco bancos estatales se reparten casi la mitad del mercado total de préstamo. El mercado de capitales está relativamente infradesarrollado, y una mayoría de empresas cotizadas son de carácter público o están controladas por el Estado (Allen, Qian y Qian, 2005). No sorprende descubrir que la mayoría del crédito bancario es concedido por bancos de propiedad estatal a empresas también de propiedad estatal o a grandes empresas privadas, mientras que las pymes afrontan sustanciales obstáculos para obtener financiación externa en el sector financiero formal.

Las necesidades financieras del enorme sector privado de China están atendidas fundamentalmente por el sistema de banca paralelo (*shadow banking*), el cual está formado por empresas financieras que operan fuera del sector bancario. Estas empresas financieras adoptan diversas formas, como sociedades fiduciarias o *trust*; préstamos entre empresas intermediados por entidades financieras (denominados préstamos comisionados o *entrusted loans*); empresas de microfinanzas; sociedades de aval, sociedades de *leasing*, casas de empeños y otros prestamistas no bancarios diversos. Desempeñan funciones similares a los bancos, pero no

están sujetos a la intensa regulación del sector bancario.

La demanda de inversión y crédito por parte de los particulares chinos se disparó durante la última década a medida que se desarrollaba una creciente clase media en el país, y la digitalización de las finanzas ha hecho mucho más fácil el préstamo entre particulares a través de Internet. China posee más de 700 millones de usuarios de Internet, muchos de los cuales han desarrollado el hábito de comprar *online* y realizar pagos digitales (*The Economist*, 2017). El crédito *peer-to-peer online* ofrece una oportunidad para que los inversores canalicen sus fondos de forma colectiva, satisfaciendo de ese modo las demandas de crédito y de inversión. Como era previsible, ante la ausencia de una regulación formal del negocio de crédito *peer-to-peer*, muchas entidades del *shadow banking* abrieron su propia página web a comienzos de la década de los 2010 para ejercer esa actividad. Los datos de Wangdai-zhijia muestran que el número de portales de OML operativos creció vertiginosamente desde tan solo 10 en 2010 hasta 3.984 en 2016 (marzo), y en términos acumulados procesó préstamos por valor de 1,745 billones de renminbis (268.400 millones de dólares). Aunque este mercado emergente es aún pequeño comparado con el mastodóntico sistema financiero del país (3), sea cual sea el parámetro con que se mida, China es el líder mundial del crédito de mercado *online*.

#### 2. ¿Por qué fracasan muchas plataformas P2P chinas?

Curiosamente, desde que el número de plataformas P2P

en China alcanzase su cénit en 2015, casi dos terceras partes de las mismas han cerrado llegados a 2019. Los años 2014 y 2015 dejaron un reguero de quiebras de plataformas en China, incluidos varios escándalos aireados por la prensa. Por cada plataforma que quebró, un gran número de inversores se vieron afectados, lo que las convirtió en fuentes de inestabilidad social. Las autoridades reguladoras bancarias chinas impusieron una serie de reglas restrictivas en 2016 y han llevado a cabo acciones correctoras para expulsar del mercado a los actores que no cumplan.

¿Qué explica esta quiebra masiva de las plataformas P2P chinas? Técnicamente, las P2P son proveedores de información, emparejando a demandantes de crédito y ofertantes de financiación en Internet, y cobrando unas comisiones de servicio por ello. El repunte de las quiebras de plataformas es prueba de que los reguladores han fracasado en gran medida en asegurar que las plataformas de crédito P2P sean meros «intermediarios de información» y no intermediarios financieros que asumen y extienden riesgo financiero. La realidad es que la mayoría de las plataformas P2P chinas son actores del *shadow banking* que, por un lado, captan depósitos de particulares en Internet ofreciéndoles rentabilidades (poco realistas) elevadas y, por otro lado, canalizan esos fondos captados hacia empresas necesitadas de financiación a tipos de interés extremadamente altos. A diferencia de los bancos, estas plataformas P2P no estuvieron reguladas hasta 2015.

La quiebra de una plataforma suele comenzar con los impagos

de los prestatarios, que provocan pérdidas para los inversores prestamistas. La plataforma, obligada a pagar a los inversores la atractiva rentabilidad prometida, tiene que recurrir en ocasiones a sus propios recursos para remunerar a dichos inversores. A medida que los recursos propios de la plataforma van menguando por los créditos morosos, debe usar los fondos de nuevos inversores para pagar a los ya existentes a fin de mantenerse en funcionamiento, derivando en fraudes de tipo piramidal conocidos como esquemas Ponzi. Aún peor, cuando el número de inversores cae hasta el punto de que los fondos aportados por los nuevos inversores no son suficientes para repagar a los existentes, cualquier impago a los inversores existentes genera pánico entre los demás, provocando que otros inversores retiren su dinero. Esto crea una situación comparable a un pánico bancario, y desemboca en la quiebra de la plataforma. Por ejemplo, el *Wall Street Journal* describió el colapso de la plataforma pequinésa de P2P EZubo en 2015 como un «esquema Ponzi estimado en 7.600 millones de dólares», en el que más de 900.000 inversores perdieron sus aportaciones (4). En 2016, Zhongjin, otra plataforma P2P con sede en Shanghai, dio en quiebra con unos fondos evadidos por valor de 4.600 millones de dólares, dejando más de 130.000 damnificados. Desde diciembre de 2015, las autoridades reguladoras de Beijing, Shanghai y Guangzhou han suspendido el registro de nuevas empresas OML y han comenzado a perseguir a los operadores fraudulentos.

### 3. Análisis sobre el sector del crédito de mercado online (OML) de China

Este apartado utiliza un exclusivo conjunto de datos de elaboración propia para estudiar el sector OML chino. Nuestro objetivo es comparar de manera sistemática las características de las plataformas «fallidas» y «en normal funcionamiento» y realizar inferencias acerca de los factores que pueden predecir la quiebra de una plataforma. Este ejercicio es útil para los directivos y reguladores a fin de identificar el riesgo de fraude y controlar las plataformas de manera oportuna en el tiempo. Los datos se han obtenido de Wangdaizhijia (<http://www.wdzj.com>), el principal instituto de estudio y seguimiento del sector OML de China.

Otros estudios empíricos utilizan datos de transacciones de una plataforma (p. ej., Prosper o Lending Club para estudiar el mercado de crédito P2P, y sus variables de interés clave son el éxito en la financiación, los precios aplicados y la tasa de impago del prestatario). Nuestro estudio difiere del suyo en que nosotros estudiamos el riesgo de quiebra de la plataforma, y nuestros datos contienen características a nivel de plataforma con frecuencia mensual. Utilizamos datos mensuales porque el OML en China tiene orígenes recientes que se remontan a 2010, y la mayoría de las plataformas OML se crearon con posterioridad a 2013. Además, un número no despreciable de plataformas quebraron en el plazo de un año; así pues, emplear el binomio plataforma-mes como unidad de observación nos permite trazar una radiografía precisa del sector OML en China.

Nuestra muestra comprende 735 plataformas únicas y 9.556 observaciones plataforma-mes con datos de variables completos desde 2011 hasta 2015. De las 735 plataformas, 476 quebraron en distintas etapas del período muestral. Si bien la muestra no cubre todas las plataformas existentes, es con mucho la representación más exhaustiva y completa de datos a nivel de plataforma del mercado OML de China.

El cuadro n.º 2 presenta la distribución de nuestra muestra. El panel A indica la distribución por provincias, y en el panel B se aprecia la distribución por años. Más de una cuarta parte de nuestras observaciones proceden de la provincia de Guangdong. Por número absoluto de quiebras, Shandong, Guangdong y Zhejiang son las que encabezan la clasificación. En términos de porcentaje de quiebras, Hainan, Shandong y Jilin son las tres provincias con los índices más altos.

La mayoría de las observaciones se concentran en 2014 y 2015. El número de observaciones crece monótonamente con el tiempo hasta 2014 y disminuye ligeramente debido a las quiebras masivas de plataformas en 2015. Las observaciones plataforma quebrada-mes representan un 4,98 por 100 de la muestra. Más de la mitad de las quiebras ocurrieron en 2015.

El cuadro n.º 3 contiene el resumen estadístico de nuestra muestra. El promedio del tipo de interés para una plataforma-mes es del 20,92 por 100, con un tipo de interés medio de primer cuartil del 24,84 por 100. El vencimiento medio de los préstamos es de 3,57 meses, y tres cuartas partes de las observaciones



CUADRO N.º 2

## DISTRIBUCIÓN DE LAS PLATAFORMAS P2P EN LA MUESTRA (2011-2015)

## PANEL A, DISTRIBUCIÓN POR PROVINCIA

| PROVINCIA    | OBS.  | PORCENTAJE DEL TOTAL OBS. | Nº. DE QUIEBRAS | PORCENTAJE DE QUIEBRAS |
|--------------|-------|---------------------------|-----------------|------------------------|
| Anhui        | 278   | 2,91                      | 22              | 7,91                   |
| Beijing      | 1.264 | 13,23                     | 21              | 1,66                   |
| Chongqing    | 167   | 1,75                      | 9               | 5,39                   |
| Fujian       | 252   | 2,64                      | 15              | 5,95                   |
| Guangdong    | 2.439 | 25,52                     | 73              | 2,99                   |
| Guangxi      | 89    | 0,93                      | 7               | 7,87                   |
| Guizhou      | 133   | 1,39                      | 5               | 3,76                   |
| Hainan       | 20    | 0,21                      | 3               | 15,00                  |
| Hebei        | 73    | 0,76                      | 5               | 6,85                   |
| Heilongjiang | 25    | 0,26                      | 1               | 4,00                   |
| Henan        | 145   | 1,52                      | 10              | 6,90                   |
| Hubei        | 346   | 3,62                      | 10              | 2,89                   |
| Hunan        | 208   | 2,18                      | 20              | 9,62                   |
| Inner Meng.  | 31    | 0,32                      | 2               | 6,45                   |
| Jiangsu      | 467   | 4,89                      | 28              | 6,00                   |
| Jiangxi      | 229   | 2,40                      | 7               | 3,06                   |
| Jilin        | 14    | 0,15                      | 2               | 14,29                  |
| Liaoning     | 44    | 0,46                      | 2               | 4,55                   |
| Ningxia      | 20    | 0,21                      | 0               | 0,00                   |
| Shandong     | 857   | 8,97                      | 124             | 14,47                  |
| Shanghai     | 802   | 8,39                      | 22              | 2,74                   |
| Shanx        | 52    | 0,54                      | 1               | 1,92                   |
| Shanxi       | 40    | 0,42                      | 1               | 2,50                   |
| Sichuan      | 457   | 4,78                      | 21              | 4,60                   |
| Tianjin      | 37    | 0,39                      | 4               | 10,81                  |
| Yunnan       | 46    | 0,48                      | 0               | 0,00                   |
| Zhejiang     | 1.021 | 10,68                     | 61              | 5,97                   |
| Total        | 9.556 | 100,00                    | 476             | 4,98                   |

## PANEL B, DISTRIBUCIÓN POR AÑO DE PLATAFORMAS P2P CHINAS (2011-2015)

| AÑO   | OBS.  | PORCENTAJE DEL TOTAL OBS. | Nº. DE QUIEBRAS | PORCENTAJE DE QUIEBRAS |
|-------|-------|---------------------------|-----------------|------------------------|
| 2011  | 29    | 0,30                      | 7               | 24,14                  |
| 2012  | 136   | 1,42                      | 12              | 8,82                   |
| 2013  | 465   | 4,87                      | 12              | 2,58                   |
| 2014  | 4.560 | 47,72                     | 181             | 3,97                   |
| 2015  | 4.366 | 45,69                     | 264             | 6,05                   |
| Total | 9.556 | 100,00                    | 476             | 4,98                   |

plataforma-mes tienen un vencimiento medio inferior a cinco meses. Este vencimiento es sustancialmente más corto que los préstamos a 3-5 años ofrecidos en las grandes plataformas OML de EE.UU. como Lending Club y Prosper. Cada mes, la media de nuevos préstamos iniciados es de 1.592 y el número de presta-

mos vivos es de 1.089. La media del volumen mensual es superior a los 81 millones de yenes (12,46 millones de dólares), con una entrada neta de flujos media de 19 millones de yenes (2,92 millones de dólares). La mediana del principal vivo es de 224 millones de yenes (34,46 millones de dólares). En cuanto a ofertantes y

demandantes de financiación, el número medio de ofertantes (2.283) por cada plataforma/mes es de 5,32 veces el de demandantes (429). Además, por el lado de los demandantes, los diez primeros prestatarios dominan casi la mitad de los préstamos vivos, lo que revela un riesgo significativo de infradiversificación; por el lado de los ofertantes, los diez mayores proveedores de fondos aportan una tercera parte de la inversión total.

A fin de comparar características entre las plataformas fallidas y las que continúan en normal funcionamiento, llevamos a cabo tres grupos de T-test, que se resumen en el cuadro n.º 4. El panel A del cuadro n.º 4 muestra la comparación entre las observaciones que son un mes anteriores a la quiebra de la plataforma y el resto de observaciones. Las observaciones anteriores en un mes a la quiebra presentaban unas menores entradas de flujos netos mensuales ( $t=-10,57$ ), un menor número de préstamos vivos ( $t=-7,69$ ), menores préstamos mensuales nuevos ( $t=-7,05$ ) y menor número de prestatarios mensuales ( $t=-11,25$ ), y mayores proporciones de los principales inversores ( $t=5,96$ ). El panel B muestra la comparación entre las observaciones procedentes de alguno de los seis meses anteriores a la quiebra de la plataforma y el resto de observaciones. Además de lo observado en el panel A, las observaciones del semestre anterior a la quiebra muestran cifras operativas aún más concentradas, y el volumen mensual ( $t=-3,10$ ), el vencimiento del préstamo ( $t=-17,89$ ), el tipo de interés ( $t=10,08$ ) y el número de ofertantes mensuales ( $t=-6,32$ ) exhiben diferencias significativas entre las plataformas fallidas y las normales. El panel C muestra



CUADRO N.º 3

## RESUMEN ESTADÍSTICO DE LA OPERATIVA MENSUAL DE LAS PLATAFORMAS P2P CHINAS (2011-2015)

| VARIABLE                  | MEDIA    | DESV. TÍP. | MÁXIMO       | P75      | MEDIANA | P25   | MÍNIMO  |
|---------------------------|----------|------------|--------------|----------|---------|-------|---------|
| M. Volume (in mm)         | 81,08    | 432,85     | 16.232,00    | 42,51    | 14,01   | 4,55  | 0,00    |
| M. Net Inflow (in mm)     | 19,49    | 108,68     | 3.846,24     | 6,59     | 0,53    | 0,00  | -648,19 |
| Loan Outst. Amt. (in mm)  | 224,73   | 1.280,85   | 68.834,03    | 104,58   | 27,62   | 7,97  | 0,00    |
| Avg. Bidding Size (in mm) | 1,46     | 66,44      | 6.530,75     | 0,08     | 0,04    | 0,02  | 0,00    |
| Top 10 Investor Prop.     | 0,35     | 0,26       | 1,00         | 0,51     | 0,30    | 0,15  | 0,00    |
| Loan Outst. Number        | 1.089,00 | 13.234,00  | 709.484,00   | 97,00    | 29,00   | 7,00  | 0,00    |
| Top 10 Borrower Prop.     | 0,58     | 0,35       | 1,00         | 0,97     | 0,61    | 0,29  | 0,00    |
| M. Loan Number            | 1.592,00 | 20.687,00  | 1.428.697,00 | 176,00   | 67,00   | 26,00 | 1,00    |
| M. Avg. Loan maturity     | 3,57     | 4,07       | 61,02        | 4,10     | 2,37    | 1,40  | 0,00    |
| M. Avg. Interest Rate (%) | 20,92    | 19,34      | 1.599,07     | 24,84    | 18,00   | 13,68 | 0,00    |
| M. Bidder Number          | 2.283,00 | 1.022,50   | 369.343,00   | 1.010,00 | 283,00  | 92,00 | 0,00    |
| M. Borrower Number        | 429,00   | 3.534,00   | 112.726,00   | 53,00    | 17,00   | 5,00  | 1,00    |

la comparación entre las observaciones de plataformas fallidas y el resto de observaciones, y arroja más diferencias significati-

vas sobre la base del panel B. En resumen, a partir de los tres paneles, concluimos que las plataformas fallidas son más inactivas

(en términos de demandantes y ofertantes de financiación, y número de préstamos) y presentan un mayor riesgo de infradiver-

CUADRO N.º 4

## CARACTERÍSTICAS DE EMPRESAS FALLIDAS Y NO FALLIDAS

|                           | <b>Panel A</b>                                                        |          |                                                                                    | <b>Panel B</b>                                                         |                                                        |              | <b>Panel C</b>                                                                   |          |              |
|---------------------------|-----------------------------------------------------------------------|----------|------------------------------------------------------------------------------------|------------------------------------------------------------------------|--------------------------------------------------------|--------------|----------------------------------------------------------------------------------|----------|--------------|
|                           | Observaciones un mes antes de la quiebra frente a otras observaciones |          |                                                                                    | Observaciones 6 meses antes de la quiebra frente a otras observaciones |                                                        |              | Ob. de plataformas fallidas frente a ob. de plataformas en normal funcionamiento |          |              |
|                           | (1): Quebró el siguiente mes=1<br>(2): Quebró el siguiente mes=0      | (1)-(2)  | (3): Quebró en los siguientes 6 meses=1<br>(4): Quebró en los siguientes 6 meses=0 | (3)-(4)                                                                | (5): Plataforma fallida=1<br>(6): Plataforma fallida=0 | (5)-(6)      |                                                                                  |          |              |
|                           | (1)                                                                   | (2)      | (3)                                                                                | (4)                                                                    | (5)                                                    | (6)          |                                                                                  |          |              |
| M. Volume (in mm)         | 47,14                                                                 | 82,83    | -35,69                                                                             | 48,05                                                                  | 90,89                                                  | -42,84***    | 48,05                                                                            | 113,53   | -65,48***    |
| M. Net Inflow (in mm)     | 1,46                                                                  | 19,89    | -18,43***                                                                          | 2,96                                                                   | 24,40                                                  | -21,44***    | 3,36                                                                             | 30,82    | -27,46***    |
| Loan Outst. Amt. (in mm)  | 195,70                                                                | 226,85   | -31,15                                                                             | 163,06                                                                 | 243,03                                                 | -79,97***    | 114,45                                                                           | 309,38   | -194,93***   |
| Avg. Bidding Size (in mm) | 1,21                                                                  | 1,50     | -0,29                                                                              | 4,47                                                                   | 0,56                                                   | 3,91         | 3,33                                                                             | 0,08     | 3,24**       |
| Top 10 Investor Prop. (%) | 42,73                                                                 | 34,70    | 8,03***                                                                            | 40,37                                                                  | 33,46                                                  | 6,91***      | 38,95                                                                            | 32,17    | 6,78***      |
| Loan Outst. Number        | 46,00                                                                 | 1.161,00 | -1.114,00***                                                                       | 43,00                                                                  | 1.400,00                                               | -1.357,00*** | 46,00                                                                            | 1.909,00 | -1.863,00*** |
| Top 10 Borrower Prop. (%) | 63,50                                                                 | 58,28    | 5,22***                                                                            | 61,02                                                                  | 52,72                                                  | 3,30***      | 60,04                                                                            | 57,40    | 2,64***      |
| M. Loan Number            | 75,00                                                                 | 1.652,00 | -1.577,00***                                                                       | 101,00                                                                 | 2.034,00                                               | -1.933,00*** | 122,00                                                                           | 2.675,00 | -2.553,00*** |
| M. Avg. Loan maturity     | 3,09                                                                  | 3,55     | -0,46**                                                                            | 2,54                                                                   | 3,87                                                   | -1,33***     | 2,55                                                                             | 4,27     | -1,72***     |
| M. Avg. Interest Rate (%) | 23,76                                                                 | 20,87    | 2,89***                                                                            | 26,84                                                                  | 19,16                                                  | 7,68***      | 27,56                                                                            | 16,04    | 11,52***     |
| M. Bidder Number          | 1.059,00                                                              | 2.348,00 | -1.289,00                                                                          | 890,00                                                                 | 2.696,00                                               | -1.807,00*** | 677,00                                                                           | 3.503,00 | -2.826,00*** |
| M. Borrower Number        | 18,00                                                                 | 449,00   | -432,00***                                                                         | 21,00                                                                  | 551,00                                                 | -529,00***   | 25,00                                                                            | 733,00   | -708,00***   |
| No. of Obs.               | 476,00                                                                | 9.080,00 |                                                                                    | 2.232,00                                                               | 7.324,00                                               |              | 4.122,00                                                                         | 5.434,00 |              |

Este cuadro ofrece un análisis comparado de las características de las plataformas fallidas y de las que están en normal funcionamiento. El panel A muestra la comparativa entre las observaciones que son un mes anterior a la quiebra de la plataforma y el resto de observaciones. El panel B muestra la comparativa entre las observaciones del semestre anterior a la quiebra de la plataforma y el resto de observaciones. Y el panel C muestra la comparativa entre las observaciones de plataformas fallidas y el resto de observaciones. Se han calculado estadísticos *T* con error típico Satterthwaite. Los signos \*\*\*, \*\* y \* denotan niveles de significación al 1 por 100, 5 por 100 y 10 por 100, respectivamente.

sificación (en términos del porcentaje del total que representan los diez principales prestatarios e inversores), con un menor vencimiento de los préstamos y un tipo de interés más alto que las plataformas normales.

En conclusión, demostramos que las plataformas fallidas son de media más pequeñas, menos activas y tienden a ofrecer préstamos con vencimiento más corto pero tipos de intereses más altos para atraer a los inversores. En cambio, estas plataformas tienen una base de inversores altamente concentrada y unos prestatarios grandes, lo que resulta en un elevado riesgo de infradiversificación. La mayoría de las plataformas quebraron en 2015 tras el desplome del mercado bursátil chino y la desaceleración económica, lo que es acorde con la interpretación de que las plataformas OML chinas son *shadow banks* muy vulnerables a los *shocks* económicos adversos.

#### IV. ESTUDIO EMPÍRICO SOBRE UNA PLATAFORMA DE CRÉDITO «P2P» LÍDER EN CHINA

En esta sección el foco de la investigación pasa desde el nivel de sector hasta el nivel de plataforma. El objetivo es comprender el modo de operar de una plataforma P2P representativa en China que aplica el modelo de «intermediario de información» de Prosper y Lending Club. Una gran parte de nuestros datos se han obtenido de Renrendai (RRD), una de las principales plataformas de crédito *peer-to-peer* que operan en China. Desde su lanzamiento oficial en septiembre de 2010, RRD ha captado más de 2,5 millones de miembros y ha fa-

cilitado operaciones de préstamo por valor de 13.000 millones de renminbis (2.000 millones de dólares) hasta el 31 de diciembre de 2015. La fuente de este conjunto de datos de elaboración propia es Changsha Aijie Information Technology Co. Ltd. (Aijie), que incluye todas las transacciones realizadas en la plataforma RRD entre 2011 y 2015.

##### 1. El proceso crediticio: solicitud, selección y concesión de financiación

El proceso de crédito en RRD comienza con una solicitud de préstamo. Para poder publicar una solicitud de préstamo en RRD, cualquier prestatario potencial debe contar con un documento nacional de identidad, un número de teléfono móvil y una cuenta bancaria. Una vez verificados los tres elementos, se clasifica al prestatario en un grado de solvencia crediticia mínimo. Para formular una solicitud de préstamo, denominada *listing*, los solicitantes deben rellenar varios campos, incluido un título, la descripción, el importe de préstamo y el vencimiento. Todos los préstamos son préstamos personales no garantizados, y su vencimiento oscila entre 1 mes y 48 meses. Además, los solicitantes también suelen aportar información personal sobre sí mismos, como su edad, sexo, formación académica, lugar de residencia, nivel de ingresos, estado civil, propiedad de vivienda, vida laboral, etcétera.

Al formular las propuestas (*listing*), los solicitantes deben suministrar un título, la descripción, el importe de préstamo (hasta un máximo establecido por la plataforma), y el vencimiento (con un vencimiento

máximo establecido por la plataforma). Todos los préstamos son préstamos personales no garantizados, y su vencimiento oscila entre 1 mes y 48 meses. RRD aplica un mecanismo de precios publicados, por el cual el tipo de interés del préstamo está determinado y refleja el «grado de solvencia» asignado por la plataforma con base en su propio modelo de calificación crediticia.

El modelo de calificación crediticia utilizado por RRD para asignar los grados no se conoce debido a su naturaleza privada. Pero, a diferencia de EE.UU. —donde pueden obtenerse las puntuaciones FICO (Fair Isaac and Company) de cualquier individuo— el sistema de *scoring* de crédito personal en China se encuentra aún en una fase embrionaria. Cada plataforma *peer-to-peer* utiliza su propio modelo de calificación crediticia basándose en la información que tiene a su alcance. Por ejemplo, RRD clasifica a los solicitantes de crédito según su solvencia en siete categorías: AA, A, B, C, D, E, y HR (alto riesgo, *high risk*). El *rating* mínimo se adquiere cuando el solicitante facilita la información mínima exigida por RRD para abrir una cuenta. Si el solicitante proporciona voluntariamente más pruebas documentales, como una nómina o un certificado de propiedad de vivienda, y estos datos son verificados por la web, su calificación crediticia mejorará. Asimismo, si el solicitante tiene un buen historial de crédito en esta plataforma, su calificación crediticia también mejorará.

Generalmente, un *listing* permanece abierto durante varios días. El gráfico 1 muestra una página típica para los prestamistas, donde se muestran todos los

*listings* activos con identificador de usuario, título del préstamo, importe de préstamo, tipo de interés ofrecido, calificación crediticia, porcentaje de financiación completado y plazo restante. Los prestamistas pueden reali-

zar búsquedas, filtrar y ordenar estos *listings*. Al hacer clic en un *listing* concreto, los prestamistas pueden visualizar la página del *listing* (véase el gráfico 2 a modo de ejemplo). En ella se recoge información detallada sobre el

solicitante, como descripción del préstamo, edad del prestatario, sexo, lugar de residencia, educación, nivel de ingresos, propiedad de vivienda, y estatus de autenticación, pero no se permiten fotografías del prestatario.

GRÁFICO 1  
PÁGINA DE EJEMPLO EN UNA PLATAFORMA PEER-TO-PEER





GRÁFICO 2  
PÁGINA DE EJEMPLO CON LISTINGS EN UNA PLATAFORMA DE CRÉDITO PEER-TO-PEER



Para pujar por un *listing*, un prestamista debe formular una puja con un importe. El importe de puja mínimo es 50 yenes (7 dólares), y RRD desalienta que los prestamistas pujen por la totalidad del préstamo. Cuando el *listing* alcanza un porcentaje de financiación del 100 por 100 se considera completado; en caso contrario, el prestatario no recibe ningún importe (véase el gráfico 3 para una ilustración). Como resultado, un préstamo completado suele tener múltiples prestamistas. Una vez que RRD verifica que el préstamo ha sido completado, los fondos se transmiten desde los prestamistas a los prestatarios, menos una comisión de servicio para la plataforma. La comisión de servicio varía dependiendo de la calificación crediticia del prestatario.

A partir de ese momento, los prestatarios están obligados a reembolsar el principal y los intereses en cuotas mensuales. Las

cantidades pagadas por el prestatario se distribuyen proporcionalmente entre los prestamistas del préstamo. Si una cantidad está impagada (es decir, el prestatario no dispone de fondos suficientes en su cuenta bancaria para pagar los intereses), RRD


hace varios intentos de recobrar el préstamo a través de email, mensajes de texto y llamadas al prestatario. No obstante, en su calidad de plataforma, RRD no asume el riesgo de crédito ligado al deudor.

## 2. Estadística descriptiva

Este apartado realiza una investigación detallada sobre el préstamo y los perfiles de los prestatarios en una plataforma de crédito *peer-to-peer* líder en China. Nuestra muestra está formada por 247.115 *listings* de préstamo publicados en RRD entre 2011 y 2015.

En el panel A del cuadro 5 se observa que en torno al 24,9 por 100 de todos los *listings* obtienen la financiación completa. De los 61.577 préstamos completamente financiados, el tamaño medio del préstamo varía significativamente entre 48.100 yenes (6.734 dólares) y 3 millones de yenes (420.000 dólares). En promedio, el tipo de interés es 2,13 veces el tipo de referencia de los préstamos, con una banda de variación

GRÁFICO 3  
PROCESO DE CROWDFUNDING DE DEUDA EN PLATAFORMAS DE CRÉDITO PEER-TO-PEER





considerable de 0,76–5,38 veces tipo de referencia de los préstamos. En comparación con la estabilidad del tipo de referencia de los préstamos de China, estas amplias diferencias de precios reflejan, al menos en parte, las diferencias de riesgo asociado a cada prestatario. La media (mediana) del vencimiento del préstamo es de 18,79 [19] meses. Construimos una variable adicional «largo plazo», que es una variable ficticia (*dummy*) que toma valor igual a uno si el vencimiento es mayor de 12 meses y cero en caso contrario. Se observa que el 80 por 100 de los prestatarios solicitan un préstamo a largo plazo. La titularidad también varía de forma considerable de unos préstamos a otros. El préstamo medio tiene 35,5 prestamistas, con una banda de oscilación entre 1 y 1.370 prestamistas. El plazo medio de puja para cada préstamo completamente financiado es de 69 minutos. Finalmente, alrededor del 5 por 100 de los préstamos completados incurren en impago.

El panel B muestra el resumen estadístico de las características de los prestatarios. La mayoría de estos son jóvenes, varones y casados, con una formación inferior a licenciado universitario y poseen bajos *scores* de crédito. El nivel mediano de ingresos de los prestatarios es inferior a los 10.000 yenes (1.400 dólares) mensuales, solo un 44 por 100 de los prestatarios son propietarios de una vivienda, y el 15,8 por 100 de ellos declaran tener una hipoteca.

### 3. Factores que determinan el éxito en la financiación

El cuadro n.º 5 contiene los resultados de una serie de variables relativas al éxito de un

prestatario a la hora de obtener financiación. El éxito es una variable *dummy* que toma valor uno si el préstamo se completa íntegramente. Fracción es la proporción de crédito obtenido en relación con el importe de préstamo solicitado. Las columnas 1 y 3 utilizan modelos *probit* y *tobit*, respectivamente, y las columnas 2 y 4 utilizan mínimos cuadrados ordinarios (MCO) para comprobar si los resultados son robustos. Nuestros modelos introducen variables de control de un conjunto completo de características del prestatario y el entorno institucional de la provincia donde este tiene su residencia.

Lo que sugieren las variables clave es, en general, consistente con las expectativas. Los prestatarios con una elevada calificación crediticia, alto nivel de ingresos, elevado nivel de educación y una larga experiencia laboral, tienen un alto grado de éxito en la financiación. Los prestatarios mujeres tienen un menor éxito que los varones. Por otro lado, tipos de interés altos pueden atraer a un buen número de inversores, conduciendo a que lo recaudado alcance una mayor proporción en relación con el importe de préstamo solicitado. Asimismo, se observa que unos tipos de interés altos señalizan un riesgo más elevado por parte del prestatario, lo que lleva a una

CUADRO N.º 5

#### ESTADÍSTICA COMPARATIVA: CARACTERÍSTICAS DE LOS PRÉSTAMOS Y LOS PRESTATARIOS EN RENRENDI (2011-2015)

| VARIABLE                                               | MEDIA   | DESV. TÍP. | MÍN.  | P50   | MÁX.   | N       |
|--------------------------------------------------------|---------|------------|-------|-------|--------|---------|
| <b>Panel A, Listing y características del préstamo</b> |         |            |       |       |        |         |
| fund                                                   | 0.249   | 0.433      | 0     | 0     | 1      | 247.115 |
| fraction                                               | 0.272   | 0.444      | 0     | 0     | 1      | 247.103 |
| words                                                  | 114.504 | 70.328     | 0     | 94    | 244    | 247.115 |
| amount                                                 | 4.819   | 7.016      | 0.3   | 3.78  | 300    | 61.577  |
| maturity                                               | 18.791  | 10.156     | 1     | 18    | 48     | 61.577  |
| long term                                              | 0.798   | 0.401      | 0     | 1     | 1      | 61.577  |
| spread                                                 | 2.132   | 0.303      | 0.762 | 2.146 | 5.379  | 61.577  |
| ownership                                              | 35.504  | 48.976     | 1     | 22    | 1.370  | 61.573  |
| default                                                | 0.054   | 0.227      | 0     | 0     | 1      | 61.577  |
| bid_time                                               | 69.136  | 461.297    | 1     | 1     | 10.051 | 61.573  |
| <b>Panel B, Características del prestatario</b>        |         |            |       |       |        |         |
| age                                                    | 32.679  | 7.458      | 17    | 31    | 71     | 247.113 |
| gender                                                 | 0.136   | 0.343      | 0     | 0     | 1      | 247.115 |
| grade                                                  | 5.975   | 1.940      | 1     | 7     | 7      | 247.115 |
| edu                                                    | 1.933   | 0.780      | 1     | 2     | 4      | 246.751 |
| marriage                                               | 0.557   | 0.497      | 0     | 1     | 1      | 247.075 |
| income                                                 | 3.133   | 1.221      | 1     | 3     | 6      | 246.361 |
| house                                                  | 0.428   | 0.495      | 0     | 0     | 1      | 247.115 |
| house_loam                                             | 0.158   | 0.365      | 0     | 0     | 1      | 247.115 |
| work_exp                                               | 2.352   | 1.019      | 1     | 2     | 4      | 246.109 |
| past_num                                               | 4.153   | 5.659      | 1     | 3     | 148    | 247.115 |

El panel A muestra la estadística descriptiva de cada *listing* y las características de cada préstamo. El panel B muestra la información estadística relativa a características demográficas, nivel de ingresos y educación de los prestatarios. Respecto a definiciones de las variables y detalles sobre su construcción, véase el Apéndice I.



CUADRO N.º 6

## FACTORES DETERMINANTES DEL ÉXITO EN LA FINANCIACIÓN EN RENRENDI (2011-2015)

|                                                     | ÉXITO                |                      | FRACCIÓN             |                      |
|-----------------------------------------------------|----------------------|----------------------|----------------------|----------------------|
|                                                     | (1)                  | (2)                  | (3)                  | (4)                  |
| <b>Características del prestatario</b>              |                      |                      |                      |                      |
| age                                                 | 0,001***<br>(0,000)  | 0,001***<br>(0,000)  | 0,001***<br>(0,000)  | 0,001***<br>(0,000)  |
| gender                                              | -0,008***<br>(0,001) | -0,008***<br>(0,001) | -0,012***<br>(0,001) | -0,012***<br>(0,001) |
| grade                                               | -0,077***<br>(0,000) | -0,077***<br>(0,000) | -0,175***<br>(0,000) | -0,175***<br>(0,000) |
| edu                                                 | 0,005***<br>(0,001)  | 0,005***<br>(0,001)  | 0,006***<br>(0,001)  | 0,006***<br>(0,001)  |
| marriage                                            | 0,007***<br>(0,001)  | 0,007***<br>(0,001)  | 0,008***<br>(0,001)  | 0,008***<br>(0,001)  |
| income                                              | 0,004***<br>(0,000)  | 0,004***<br>(0,000)  | 0,006***<br>(0,001)  | 0,005***<br>(0,001)  |
| house                                               | -0,005***<br>(0,001) | -0,005***<br>(0,001) | -0,000***<br>(0,001) | -0,001***<br>(0,001) |
| house_loam                                          | 0,004***<br>(0,002)  | 0,004***<br>(0,002)  | 0,007***<br>(0,002)  | 0,007***<br>(0,002)  |
| work_exp                                            | 0,007***<br>(0,001)  | 0,007***<br>(0,001)  | 0,010***<br>(0,001)  | 0,010***<br>(0,001)  |
| spread                                              | -0,032***<br>(0,001) | -0,032***<br>(0,001) | 0,014***<br>(0,001)  | 0,014***<br>(0,001)  |
| words                                               | 0,000***<br>(0,000)  | 0,000***<br>(0,000)  | 0,000***<br>(0,000)  | 0,000***<br>(0,000)  |
| past_num                                            | -0,002***<br>(0,000) | -0,002***<br>(0,000) | -0,003***<br>(0,000) | -0,003***<br>(0,000) |
| <b>Características económicas e institucionales</b> |                      |                      |                      |                      |
| B_SC_index                                          | 0,002***<br>(0,000)  | 0,002***<br>(0,001)  | 0,002***<br>(0,000)  | 0,003***<br>(0,001)  |
| law_office                                          |                      | -0,046***<br>(0,007) |                      | -0,062***<br>(0,008) |
| loan                                                |                      | 0,010***<br>(0,002)  |                      | 0,015***<br>(0,002)  |
| pgdp                                                |                      | 0,002***<br>(0,000)  |                      | 0,002***<br>(0,000)  |
| Constant                                            |                      |                      | 1.463***<br>(0,007)  | 1.447***<br>(0,007)  |
| Observaciones                                       | 243.042              | 243.042              | 243.030              | 243.030              |
| Pseudo R cuadrado                                   | 0,604                | 0,604                | 0,652                | 0,652                |

Este cuadro presenta los resultados de las regresiones efectuadas respecto a los indicadores éxito y fracción (crédito obtenido en relación al solicitado) a partir de las características de los prestatarios. Se incluyen variaciones ficticias de cada año. El panel A muestra los resultados para el índice de capital social. Las columnas 1 y 2 aplican modelos *probit*. Las columnas 3 y 4 usan regresiones por MCO. El panel B refleja los resultados para los cuatro proxies del capital social sobre éxito (*probit*) y fracción (MCO). Las características personales del prestatario y las variables económicas y financieras de la región están incluidas pero no se muestran. Los errores estándar robustos se muestran en paréntesis. \*\*\*, \*\* y \* denotan significación estadística a los niveles 1 por 100, 5 por 100 y 10 por 100, respectivamente. Para conocer las definiciones de las variables y detalles sobre su construcción, véase el Apéndice I.

materialización más baja de los préstamos.

También controlamos por las variables de entorno institucional de la provincia de la que procede el prestatario. Consistente con las expectativas, el PIB per capita, el *stock* de capital social y el desarrollo financiero (volumen de préstamo bancario respecto al PIB) de la provincia de procedencia tienen un efecto positivo y estadísticamente significativo en el éxito en la financiación. Una excepción la constituye la variable *law\_office*, que guarda una correlación negativa con el éxito en la financiación. Interpretamos este resultado en el sentido de que los prestamistas individuales perciben una práctica jurídica más intensa en una provincia como un mayor coste legal para hacer valer sus derechos.

#### 4. Factores que determinan la tasa de impagos

El cuadro n.º 6 muestra los resultados de la regresión sobre los determinantes de la probabilidad de impago de un prestatario. Nuestra muestra incluye todos los préstamos originados con éxito. La columna 1 utiliza el modelo *probit* y la columna 2 emplea el modelo *logit*. En consonancia con las expectativas, los prestatarios con calificaciones de crédito más bajas y un menor nivel de educación tienen una mayor probabilidad de impago del préstamo. Además, encontramos que las características institucionales de la provincia de la que procede el prestatario tienen un impacto en las tasas de impago. Los prestatarios que residen en provincias con un menor *stock* de capital social y un menor desarrollo financie-

CUADRO N.º 7

## FACTORES DETERMINANTES DE LAS TASAS DE IMPAGO EN RENRENDI (2011-2015)

| VARIABLES                                           | (1)<br>PROBIT        | (2)<br>LOGIT         |
|-----------------------------------------------------|----------------------|----------------------|
| <b>Características del prestatario</b>              |                      |                      |
| age                                                 | 0,001***<br>(0,000)  | 0,001***<br>(0,000)  |
| gender                                              | 0,002<br>(0,003)     | 0,002<br>(0,002)     |
| grade                                               | 0,060***<br>(0,003)  | 0,079***<br>(0,003)  |
| edu                                                 | -0,014***<br>(0,001) | -0,014***<br>(0,001) |
| income                                              | 0,004***<br>(0,001)  | 0,004***<br>(0,001)  |
| house                                               | 0,005***<br>(0,002)  | 0,005***<br>(0,002)  |
| house_loam                                          | -0,018***<br>(0,002) | -0,018***<br>(0,002) |
| work_exp                                            | -0,001*<br>(0,001)   | -0,002**<br>(0,001)  |
| spread                                              | 0,003*<br>(0,002)    | 0,004*<br>(0,002)    |
| words                                               | 0,000*<br>(0,000)    | 0,000*<br>(0,000)    |
| <b>Características económicas e institucionales</b> |                      |                      |
| B_SC_index                                          | -0,002**<br>(0,001)  | -0,002***<br>(0,001) |
| law_office                                          | -0,006<br>(0,010)    | -0,004<br>(0,010)    |
| Loan                                                | -0,009***<br>(0,003) | -0,009***<br>(0,003) |
| Pgdp                                                | 0,000<br>(0,001)     | 0,000<br>(0,001)     |
| Pseudo R cuadrado                                   | 0,477                | 0,484                |
| Observaciones                                       | 60.970               | 60.970               |

Este cuadro presenta los resultados de la regresión de las tasas de impago para un determinado préstamo a partir de las características de prestatario y sus características institucionales provinciales. Las columnas 1 y 2 implementan regresiones probit y logit (efectos marginales), respectivamente. Los efectos fijos de cada año están incluidos. Los errores estándar robustos agrupados a nivel de provincia se muestran en paréntesis. \*\*\*, \*\* y \* denotan significación estadística al nivel del 1 por 100, 5 por 100 y 10 por 100, respectivamente. Para conocer las definiciones de las variables y detalles sobre su construcción, véase el Apéndice I.

ro (aproximado por el cociente entre préstamos bancarios y PIB) presentan una mayor probabilidad de impago.

## V. CONCLUSIONES

En la pasada década, las innovaciones tecnológicas aplicadas al mundo de las finanzas han

hecho posible el crédito *online* entre particulares anónimos sin la intervención de intermediarios financieros. El presente artículo revisa la creciente literatura empírica sobre el crédito *peer-to-peer*, con el objetivo de obtener nuevas perspectivas a partir de los datos. Asimismo, se analiza el mercado chino de crédito *peer-to-peer*, utilizando tanto datos a nivel de

plataforma-mes procedentes de 735 portales P2P como datos a nivel de transacción obtenidos a partir de una plataforma P2P líder en China, RRD.

Nuestra revisión de la literatura revela que el interés académico sobre el crédito P2P en la última década se focaliza en la comprensión de: 1) el comportamiento de los inversores y cómo procesan la información; 2) el diseño óptimo del mecanismo en las plataformas *peer-to-peer* (P2P); y 3) la interrelación existente entre el crédito P2P y la financiación bancaria. Observamos que las teorías económicas sobre contratación, asimetría de información y selección adversa proporcionan una herramienta útil para comprender el mercado de crédito *peer-to-peer*. De forma similar a los bancos, los particulares que actúan como prestamistas también buscan señales de calidad sobre el prestatario basadas en información tanto «dura» como «blanda», si bien exhiben sesgos psicológicos. Las plataformas P2P, por su parte, están experimentando y optimizando su diseño de mecanismos para maximizar el volumen de contratación y reducir las tasas de impago. Hasta ahora, la evidencia empírica respalda más una relación de «sustitución» que de «complementariedad» entre el crédito P2P y el crédito bancario.

Nuestro examen del mercado de crédito P2P chino muestra que, comparadas con las plataformas P2P en normal funcionamiento, las plataformas fallidas son, en promedio, más pequeñas, tienen un menor número de inversores y tienden a ofrecer préstamos con vencimientos más cortos, pero tipos de interés más altos (para atraer inversores). Por

otro lado, las plataformas fallidas suelen tener una base inversora altamente concentrada y prestatarios grandes. Esta evidencia es consistente con la idea de que, a diferencia de sus homólogos en Estados Unidos, muchas plataformas P2P pequeñas en China son bancos en la sombra y no meros «intermediarios de información». La quiebra masiva de plataformas en China se debe a la selección adversa, la falta de supervisión regulatoria, una incorrecta gestión del riesgo y casos de fraude.

Nuestro último conjunto de análisis utiliza datos a nivel de transacción procedentes de una plataforma de crédito P2P china representativa que imita el diseño de mecanismo de Prosper Marketplace. En línea con las expectativas, la calificación de crédito del prestatario, su nivel de ingresos y el nivel de formación académica son variables que predicen su éxito en la búsqueda de financiación (correlación positiva), mientras que predicen inversamente su impago (correlación negativa). Además, encontramos que el entorno institucional de la provincia de procedencia del prestatario es relevante: un mayor desarrollo financiero y un *stock* de capital social más elevado predicen positivamente el éxito en la financiación y negativamente el impago. Nuestra evidencia es consistente con prestamistas racionales a nivel colectivo que tienen en cuenta información tanto «dura» como «blanda» al tomar decisiones de inversión.

Son varias las áreas para el desarrollo de futuras investigaciones empíricas. Primero, existe una insuficiente investigación sobre las dimensiones internacionales del crédito P2P. Por ejem-

plo, la investigación actual sobre P2P se enfoca casi exclusivamente en EE.UU., pero se sabe poco sobre la razón de que China y otras economías emergentes, con un sector financiero e instituciones de mercado menos desarrollados, estén convirtiéndose en los mercados líderes del crédito P2P. Segundo, la revolución *fintech* abre oportunidades para que los investigadores accedan a nuevos conjuntos de datos, lo que ayudará a mejorar la comprensión de cómo funciona este mercado con mayor nivel de detalle. Por ejemplo, el análisis actual se centra en cómo evalúan colectivamente los inversores a los prestatarios individuales (lo que se ha denominado la «sabiduría colectiva» o «de la multitud»); sin embargo, convendría también estudiar cómo pujan los inversores individuales. Tercero, como observan Balyuk y Davydenko (2019), una tendencia importante en el desarrollo del crédito *online* es la «reintermediación»: las plataformas de crédito P2P se diseñaron en un principio para permitir a prestatarios y prestamistas interactuar sin necesidad de bancos que intermediasen, pero con el tiempo han evolucionado desde simples puntos de contratación para convertirse en nuevos intermediarios de crédito. A medida que el *software* de las plataformas se vuelve más inteligente, cada vez más prestamistas están adoptando estrategias pasivas de inversión y subcontratando la toma de decisiones a las plataformas. El riesgo moral y las implicaciones para el bienestar social de esta tendencia son temas interesantes de investigación. Cuarto, utilizando el P2P como ejemplo, una pregunta fundamental es hasta qué punto el desarrollo tecnológico afecta al nuevo equilibrio en el sector financiero. Lo

que vemos es que, por un lado, las entidades financieras tradicionales están volviéndose cada vez más expertas en tecnología para mejorar su toma de decisiones y productividad. Por otro lado, las empresas tecnológicas están reinventando el modelo de negocio de las finanzas y compitiendo más directamente con los intermediarios financieros tradicionales. Ejemplos de esto incluyen el crédito P2P, el *payTech*, los bancos virtuales, el *insurTech*, el *robo-advisory* (asesoramiento digital basado en algoritmos) y el *wealthTech* basado en inteligencia artificial. La interrelación entre las empresas financieras tradicionales y las tecnológicas (incluyendo sus externalidades) es un tema fascinante que puede ser objeto de futuros estudios empíricos.

## NOTAS

(\*) Otras afiliaciones: Banco de Finlandia y Universidad de Sidney.

(\*\*) Artículo traducido del inglés por Jon García.

(1) <https://www.transparencymarketresearch.com/pressrelease/peer-to-peer-lending-market.htm>

(2) <https://www.pymnts.com/news/international/2018/china-protestors-p2p-lending-regulation-fraud-debt/>

(3) Por ejemplo, el saldo vivo de crédito P2P ascendía en torno al 0,8 por 100 de los préstamos bancarios totales en China en 2016 (The Economist, 2017).

(4) Se acusó a la compañía de los delitos de captación ilegal de fondos, apropiación indebida y desfalco. Véase C.W. Yap, «China Calls Lending Platform Ezubo a \$7.6 Billion Ponzi Scheme», *Wall Street Journal*, Feb 2, 2016, disponible en <http://www.wsj.com/articles/china-calls-lending-platform-ezubo-a-7-6-billion-ponzi-scheme-1454313780>

(5) Medimos el *stock* de capital social de una provincia a través de un índice compuesto, basado en el análisis de componentes principales de cuatro variables: 1) donaciones voluntarias y no remuneradas de sangre, ajustado por la escala de la población; 2) número de ONG, ajustado por la escala de la

población; 3) una encuesta nacional china en la que se pide a los entrevistados que ordenen «las cinco provincias donde las empresas son más fiables»; y 4) una encuesta nacional china en la que se pide a los entrevistados que califiquen «cómo de fiables son las personas de su ciudad». Para una definición de cada variable véase el Apéndice I.

#### BIBLIOGRAFÍA

- AKERLOF, G. (1970). The market for «lemons»: Quality uncertainty and the market mechanism. *The Quarterly Journal of Economics*, 84(3), pp. 488-500.
- ALLEN, F., QIAN, J. y QIAN, M. J. (2005). Law, finance, and economic growth in China. *Journal of Financial Economics*, 77(1), pp. 57-116.
- ALVESSON, M. y DEETZ, M. (2000). *Doing critical management research*. London: Sage.
- BALYUK, T. y DAVYDENKO, S. A. (2019). Reintermediation in Fintech: Evidence from online lending. *SSRN Working Paper*. Disponible en: <https://ssrn.com/abstract=3189236>
- BUTLER, A. W., CORNAGGIA, J. y GURUN, U. G. (2017). Do local capital market conditions affect consumers' borrowing decisions? *Management Science*, December, pp. 4175-4187.
- D'ACUNTO, F., PRABHALA, N. y ROSSI, A. (2019). The promises and pitfalls of robo-advising. *Review of Financial Studies*, 32(5), pp. 1983-2020.
- DU, N. H., LI, L. F., LU, T. y LU, X. H. (2019). Prosocial compliance in P2P lending: A natural field experiment. *Management Science*, Articles in Advance, pp. 1-19.
- DUARTE, J., SIEGEL, S. y YOUNG, L. (2012). Trust and credit: The role of appearance in peer-to-peer lending. *Review of Financial Studies*, 25(8), pp. 2455-2484.
- ELLIOTT, D., KROEBER, A. y YU, Q. (2015). Shadow banking in China: A primer. Washington: Brookings Institution.
- GILBERT, D. y HIXON, J. (1991). The trouble of thinking: Activation and application of stereotypic beliefs. *Journal of Personality and social Psychology*, 60(4), pp. 509-517.
- GOLDSTEIN, I., JIANG, W. y KAROLYI, G. A. (2019). To fintech and beyond. *The Review of Financial Studies*, 32(5), pp. 1647-1661.
- HERZENSTEIN, M., DHOLAKIA, U. M. y ANDREWS, R. L. (2011). Strategic herding behavior in peer-to-peer loan auctions. *Journal of Interactive Marketing*, 25(1), pp. 27-36.
- HILDEBRAND, T., PURI, M. y ROCHOLL, J. (2017). Adverse Incentives in Crowdfunding. *Management Science*, 63(3), pp. 587-608.
- IYER, R., KHWAJA, A. I., LUTTMER, E. F. P. y SHUE, K. (2016). Screening peers softly: Inferring the quality of small borrowers. *Management Science*, 62(6), pp. 1554-1577.
- LIN, M., PRABHALA, N. R. y VISWANATHAN, S. (2013). Judging borrowers by the company they keep: Friendship networks and information asymmetry in online peer-to-peer lending. *Management Science*, 59(1), pp. 17-35.
- LIN, M. y VISWANATHAN, S. (2016). Home bias in online investments: An empirical study of an online crowdfunding market. *Management Science*, 62(5), pp. 1393-1414.
- MASSARO, M., DUMAY, J. y GUTHRIE, J. (2016). On the shoulders of giants: undertaking a structured literature review in accounting. *Accounting, Auditing and Accountability Journal*, 29(5), pp. 767-801.
- MICHEL, J. (2012). Do unverifiable disclosures matter? Evidence from peer-to-peer lending. *The Accounting Review*, 87(4), pp. 1385-1413.
- PARAVISINI, D., RAPPOPORT, V. y RAVINA, E. (2017). Risk aversion and wealth: Evidence from person-to-person lending portfolios. *Management Science*, 63(2), pp. 279-297.
- TANG, H. (2019). Peer-to-peer lenders versus banks: Substitutes or complements? *Review of Financial Studies*, 32(5), pp. 1900-1938.
- VALLEE, B. y ZENG, Y. (2019). Marketplace lending: A new banking paradigm? *Review of Financial Studies*, 32(5), pp. 1939-1982.
- WEI, Z. Y. y LIN, M. F. (2017). Market Mechanisms in Online Peer-to-Peer Lending. *Management Science*, 63(12), pp. 4236-4257.
- ZHANG, J. y LIU, P. (2012). Rational herding in microloan markets. *Management Science*, 58(5), pp. 892-912.

## APÉNDICE I

## DEFINICIÓN DE LAS VARIABLES Y FUENTES DE LOS DATOS

| DEFINICIONES                           |                                                                                                                                                                                                                                                                                                                                        | FUENTE                                              |
|----------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------|
| <b>Características del prestatario</b> |                                                                                                                                                                                                                                                                                                                                        |                                                     |
| grade                                  | Score crediticio de los prestatarios cuando se crea el <i>listing</i> , con valores de 1 (alto) a 7 (bajo)                                                                                                                                                                                                                             | RRD                                                 |
| age                                    | Edad del prestatario                                                                                                                                                                                                                                                                                                                   | RRD                                                 |
| gender                                 | Variable ficticia que toma valor 1 si el prestatario es mujer y 0 si es hombre                                                                                                                                                                                                                                                         | RRD                                                 |
| edu                                    | Toma valor 4 si el nivel máximo de educación obtenido por el prestatario es un título de máster o superior, 3 si es licenciatura universitaria, 2 si es educación post-terciaria, y 1 si es secundaria o inferior.                                                                                                                     | RRD                                                 |
| work_exp                               | Duración en el empleo en años. Los valores posibles van de 1 a 4, siendo 1 menos de un año, 2 entre un año y tres años, 3 entre tres y cinco años, y 4 más de cinco años.                                                                                                                                                              | RRD                                                 |
| income                                 | Ingresos mensuales declarados por el prestatario durante el proceso de registro. Los valores posibles van de 1 a 6, siendo 1 menos de 1.000 renminbis, 2 entre 1.000 y 5.000 renminbis, 3 entre 5.000 y 10.000 renminbis, 4 entre 10.000 y 20.000 renminbis, 5 entre 20.000 renminbis y 50.000 renminbis, y 6 más de 50.000 renminbis. | RRD                                                 |
| marriage                               | Variable ficticia que toma valor 1 si el prestatario está casado y 0 en otro caso                                                                                                                                                                                                                                                      | RRD                                                 |
| house                                  | Variable ficticia que toma valor 1 si el prestatario posee una vivienda y 0 en otro caso                                                                                                                                                                                                                                               | RRD                                                 |
| house_loan                             | Variable ficticia que toma valor 1 si el prestatario tiene una hipoteca sobre su vivienda y 0 en otro caso                                                                                                                                                                                                                             |                                                     |
| ownership                              | Numero de pujas relativas a un <i>listing</i> cuando el <i>listing</i> está completamente financiado                                                                                                                                                                                                                                   | RRD                                                 |
| past_num                               | Número de préstamos realizados en el pasado                                                                                                                                                                                                                                                                                            | RRD                                                 |
| <b>Información sobre el préstamo</b>   |                                                                                                                                                                                                                                                                                                                                        |                                                     |
| interest rate                          | Tipo de interés que paga el prestatario por el préstamo (el tipo es ajustado respecto al tipo de referencia de la RPC)                                                                                                                                                                                                                 | RRD                                                 |
| amount                                 | Importe de préstamo solicitado en múltiplos de 10.000 renminbis                                                                                                                                                                                                                                                                        | RRD                                                 |
| bid amount                             | Importe pujado sobre el préstamo en múltiplos de 10.000 renminbis                                                                                                                                                                                                                                                                      | RRD                                                 |
| bid_ratio                              | Ratio de tamaño de puja sobre importe solicitado                                                                                                                                                                                                                                                                                       | RRD                                                 |
| maturity                               | Vencimiento del préstamo en meses                                                                                                                                                                                                                                                                                                      | RRD                                                 |
| fund                                   | Indicador que toma valor 1 si un <i>listing</i> es completamente financiado y cero en otro caso                                                                                                                                                                                                                                        | RRD                                                 |
| fraction                               | Proporción de lo recaudado sobre el total solicitado                                                                                                                                                                                                                                                                                   | RRD                                                 |
| ownership                              | Número de prestamistas participantes en un préstamo dado                                                                                                                                                                                                                                                                               |                                                     |
| listing date                           | Fecha de creación del <i>listing</i>                                                                                                                                                                                                                                                                                                   | RRD                                                 |
| bid time                               | Tiempo (en segundos) entre el momento de creación del <i>listing</i> y el momento en que queda completamente financiado                                                                                                                                                                                                                | RRD                                                 |
| content                                | Estado aportado por el prestatario en la solicitud de préstamo                                                                                                                                                                                                                                                                         | RRD                                                 |
| words                                  | Número de palabras utilizadas por el prestatario en el texto del <i>listing</i>                                                                                                                                                                                                                                                        | RRD                                                 |
| default                                | Indicador que toma valor 1 si el estatus de préstamo es "en recobro por la plataforma" o "demorado" y cero en otro caso.                                                                                                                                                                                                               | RRD                                                 |
| <b>Variable provincial</b>             |                                                                                                                                                                                                                                                                                                                                        |                                                     |
| SC_index                               | Construida aplicando ponderaciones (coeficiente) a cuatro proxies estandarizados del capital social                                                                                                                                                                                                                                    | Estimación de los autores                           |
| blood                                  | Cantidad de sangre, en mililitros, donada por voluntarios en una provincia dividida por su población en 2000                                                                                                                                                                                                                           | Asociación china de transfusiones de sangre en 2000 |
| NGO                                    | La participación en ONG se mide como el número de miembros inscritos en ONG por mil habitantes en una provincia                                                                                                                                                                                                                        | Anuario Estadístico de China, varios años           |



## APÉNDICE I

## DEFINICIÓN DE LAS VARIABLES Y FUENTES DE LOS DATOS (CONTINUACIÓN)

|            | DEFINICIONES                                                                                                                                                                                                                                                      | FUENTE                                                                                    |
|------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------|
| enterprise | <i>Enterprise Survey System</i> (Confianza 3: confianza en empresas). En esta encuesta, los directivos responden a la siguiente pregunta: "De acuerdo a su experiencia, ¿cuáles son las cinco provincias donde las empresas son más fiables"                      | Zhang y Ke (2003)                                                                         |
| citizen    | Respuesta dada a la pregunta: "¿Cómo de fiable es la gente en su ciudad?" Las respuestas van de 1 ("muy poco fiable") a 5 ("muy fiable"). Capturamos el nivel de fiabilidad de una región calculando la puntuación media de las ciudades dentro de una provincia. | <i>Encuesta General Social de China (CGSS)</i>                                            |
| pgdp       | PIB en la provincia en múltiplos de 10.000 renminbis dividido por la población de la provincia                                                                                                                                                                    | <i>Anuario Estadístico de China</i> , varios años                                         |
| law_office | Número de bufetes de abogados por diez mil habitantes de una provincia                                                                                                                                                                                            | Informes provinciales de exámenes de cualificación para abogados y contables, varios años |
| loan       | Relación entre volumen total de préstamos bancarios y PIB de una provincia                                                                                                                                                                                        | <i>Anuario Estadístico de China</i> , diversos años                                       |

# SESGOS DE COMPORTAMIENTO EN LOS MERCADOS DE CRÉDITO

David PEÓN

Universidade da Coruña

## Resumen

Las finanzas conductuales ofrecen una interpretación intuitiva de los ciclos de crédito bancario. Tras resumir los principales sesgos de comportamiento, y las anomalías que generan en los mercados financieros, profundizamos en el efecto que tienen en la gestión de la información por parte de la banca. Revisamos varios modelos basados en sesgos por parte de algunas de las entidades que ofertan crédito. La interpretación conductual implica cuestiones regulatorias relevantes: una industria bancaria de exquisito funcionamiento estaría, aun así, expuesta a los sesgos de comportamiento en algunas de sus entidades.

*Palabras clave:* finanzas conductuales, sesgos de comportamiento, ciclos de crédito, eficiencia bancaria, exceso de confianza.

## Abstract

The behavioral finance offers an intuitive interpretation of bank credit cycles. After summarising the main behavioral biases, and the anomalies they lead to in financial markets, we delve into the effect they have on information analysis by banks. We review several models based on biased competition by some of the banks that offer credit. The behavioral interpretation implies relevant regulatory issues: an exquisitely functioning banking industry would still be exposed to the behavioral biases of some market participants.

*Keywords:* behavioral finance, behavioral biases, credit cycles, banking efficiency, overconfidence.

*JEL classification:* D91, E32, E51, G01.

## I. INTRODUCCIÓN


Las finanzas del comportamiento (*behavioral finance*, *BF*) analizan la influencia de la psicología humana en la toma de decisiones financieras a nivel particular, y en los mercados financieros a nivel global. Los economistas conductuales tienen la convicción de que un mayor realismo respecto a los fundamentos psicológicos mejorará los campos de la economía y las finanzas. El área cuenta con una creciente aceptación y reconocimiento entre académicos y autoridades, incluyendo varios Premios Nobel en los últimos años, pero el debate continúa. En particular, el área ha estado más centrada en el estudio de los mercados financieros, y pese a ello no cuenta a día de hoy con una alternativa teórica unificada y generalmente aceptada sobre el funcionamiento de los mismos. Y, en otros ámbitos, la disciplina es aún incipiente.

Uno de los ámbitos de reciente desarrollo es la *BF* aplicada a los mercados de crédito bancario. La crisis financiera de 2007 vino precedida, en la mayor parte de las economías, por un auge del crédito y de los precios de los activos. Sin ánimo de exhaustividad, sirvan varios ejemplos. En los EE.UU., el valor de mercado de los activos residenciales aumentó del 45 por 100 a casi el 75 por 100 del PIB entre 1997 y 2006, impulsado por el crédito: la ratio entre la deuda de

los hogares y el valor de los activos residenciales aumentó de 0,68 en 1997 a 0,93 en 2006 (Boz y Mendoza, 2014). El colapso crediticio posterior supuso graves restricciones para las empresas, en particular pymes (Carbó-Valverde, Rodríguez-Fernández y Udell, 2016). Los préstamos bancarios a las pymes se redujeron significativamente tras la crisis financiera: un 47 por 100 en la Unión Europea de 2008 a 2011, entre el 21 por 100 en Italia y el 82 por 100 en Irlanda (BCE, 2012; McGuinness y Hogan, 2016). Como es de esperar, el crédito comercial pasó a desempeñar un papel sustitutivo. García-Appendini y Montoriol-Garriga (2013) muestran cómo las empresas con liquidez suficiente antes de la crisis casi duplicaban el crédito comercial concedido a sus clientes durante la misma.

En el caso español, el gráfico 1 compara el crecimiento del crédito a los hogares y empresas con la evolución del PIB. Entre 1996 y el estallido de la crisis, el volumen de crédito se multiplicó por seis mientras el PIB nominal apenas se duplicaba. A partir de entonces, la corrección ha sido significativa también, primero con una interrupción abrupta del ritmo de crecimiento del crédito, y luego con una disminución de un tercio del crédito total pendiente de pago tras la crisis de la deuda soberana hasta el año 2019. Buena parte de esta corrección se ha debido a la reducción de nuevo crédito bancario

GRÁFICO 1  
CRÉDITO A LOS HOGARES Y EMPRESAS. ESPAÑA, 1996-2019



Fuentes: Elaboración propia a partir de los datos del Banco de España (BE) e Instituto Nacional de Estadística (INE).

concedido, que en el caso de las pymes ha alcanzado el 66 por 100 (McGuinness y Hogan, 2016). Ello está en línea con lo observado por Ferrando, Popov y Udell (2017) para el conjunto de países más afectados por la crisis de deuda soberana, donde las empresas han visto como se les negaba el crédito, o bien se le racionaba pagando tipos de interés más altos. Desde entonces, la industria bancaria atraviesa un período de tribulaciones. A nivel europeo, las autoridades fomentaron procesos de consolidación bancaria como solución a la crisis bancaria. En España, el sector bancario experimentó un completo proceso de reestructuración: los más de cincuenta bancos y cajas de ahorros que poseían la mayoría de los activos antes de 2009 (FMI, 2012) se transformaron en diez grupos con el 80 por 100 de los activos después del año 2012, y las cajas de ahorros desaparecieron. Los efectos continúan actualmente. La tendencia del sector continúa bajista en los mercados financieros, con ratios

de valor de mercado sobre libros inferiores a 1 en muchos casos ante la incerteza de su modelo de negocio y los cambios en el sector, plagados de vocablos anglosajones: *fintech*, *big data*, *blockchain*, *criptodivisas*... Los esfuerzos por mejorar la estabilidad del sistema han sido múltiples, tanto a nivel individual como particularmente a nivel macroprudencial.

El objetivo de este artículo se enmarca en los más generales de este número monográfico: acercamos a la realidad de esta industria en transformación y los retos que supone para entidades, reguladores y clientes, profundizando, en particular, en el papel de las finanzas del comportamiento en la gestión de la información en banca. Para ello, contribuimos con una revisión de los modelos de la economía conductual que pretenden explicar el papel de los sesgos de comportamiento en la reciente crisis crediticia.

Un número creciente de artículos, algunos de los cuales aquí revisaremos, ofrecen una interpretación intuitiva de los canales a través de los cuales se alimenta el *boom* crediticio. La novedad principal de estos modelos estriba en su enfoque: se toma en consideración también los sesgos de oferta, es decir, por parte de las entidades financieras que ofertan crédito, no por parte de los clientes, o no únicamente, al menos. La banca, al igual que los reguladores y cualquier otro agente, también muestran sesgos de comportamiento. La principal crítica que se deriva de ellos es relevante: los procesos de consolidación bancaria pueden ser cuestionables si hace más sensible al mercado a los rasgos de comportamiento.

Hay, desde luego, otras muchas explicaciones a la reciente crisis bancaria que no incluyen una interpretación conductual, incluyendo el papel de los incentivos, las titulizaciones, el riesgo moral en la toma de riesgos por parte de las entidades, o la desregulación de los préstamos predatorios. La explicación conductual no tiene siquiera por qué ser la más plausible; pero sí es, si cabe, la menos exigente: una industria bancaria de exquisito funcionamiento estaría expuesta a los sesgos de comportamiento en algunas de sus entidades. Ello genera procesos de auge y contracción del crédito debidos a que, cuando bancos racionales compiten con otros sesgados, les resulta beneficioso imitar el comportamiento de los sesgados.

La estructura del artículo es la siguiente. En primer lugar, presentamos las finanzas del comportamiento, con especial atención tanto a los principales sesgos de comportamiento identificados en la literatura, como a sus principales efectos en los mercados financieros. Las secciones tercera y cuarta abordan el estudio del impacto de los sesgos de comportamiento en los mercados de crédito bancario en particular. Para ello, la sección tercera sintetiza los canales de transmisión de los sesgos de comportamiento hacia el crédito concedido por las entidades, conforme a varios modelos teóricos disponibles. Posteriormente, en la cuarta sección, se aborda la interpretación de los ciclos de crédito conforme a la literatura conductual. El artículo termina con un resumen de las contribuciones de estos modelos, así como sus principales limitaciones, y una serie de conclusiones de política económica.

## II. LAS FINANZAS DEL COMPORTAMIENTO

La *BF* es el campo más relevante de la economía conductual, la cual proporciona desde hace décadas

evidencia de que las personas muestran preferencias, creencias y toma de decisiones atípicas que llevan a un comportamiento no convencional en sus decisiones económicas (Delia Vigna, 2009). Sugiere un enfoque más amplio al del *homo economicus* tradicional, basado en una combinación de ciencias sociales –psicología y economía, pero también sociología, demografía, antropología e historia– describiendo cómo se comportan las personas, en contraposición a cómo deberían comportarse (Shiller, 2000b). El resultado es un marco teórico en el que los mercados financieros no son algo externo a nosotros: somos nosotros. Cómo los percibimos, cómo queremos que sean y cómo los estudiamos son cuestiones entrelazadas (Frankfurter, McGoun y Allen, 2004).

Centraremos esta sección en dos epígrafes: los principales sesgos de comportamiento identificados en la literatura, y las anomalías que generan en los mercados financieros.

### 1. Sesgos de comportamiento

La información que debemos manejar para la toma de decisiones económicas y financieras es vasta, dispersa, cambia continuamente y su recopilación es costosa. Por ello, a menudo empleamos reglas simples, intuitivas y a menudo inconscientes, que simplifican o ignoran la información disponible en el momento de tomar decisiones. Son los denominados heurísticos, atajos para un procesamiento de información más eficiente (Marewski, Gaissmaier y Gigerenzer, 2010). En algunos casos –y también dependiendo de los autores– los heurísticos pueden ser una manera eficiente para la toma de decisiones racionales, o bien llevar a los agentes a cometer errores de juicio. Los sesgos de comportamiento serían, en ese caso, la tendencia a razonar de manera que conduzca a errores o desviaciones sistemáticas respecto al estándar de racionalidad.

La economía conductual proporciona amplia evidencia de que los seres humanos somos vulnerables a los sesgos de comportamiento, mostramos prejuicios en la toma de decisiones, nos vemos afectados por el marco de decisión, mostramos preferencias inconsistentes en el tiempo, y nos vemos influenciados por el comportamiento de otras personas y el entorno. Con ello, los modelos de racionalidad limitada (Simon, 1957) han venido a sustituir los modelos de toma de decisiones racional. Muchos son los autores que han proporcionado las más diversas taxonomías de los principales sesgos de conducta.

Tratar de ofrecer una síntesis es tarea compleja, ya que las reglas de clasificación empleadas son diversas, y diferentes autores a menudo usan nombres diferentes para conceptos similares (Peón, 2015). Intentamos sintetizar primero algunos de los principales autores:

Las primeras taxonomías de Daniel Kahneman y Amos Tversky (Kahneman, Slovic y Tversky, 1982; Tversky y Kahneman, 1992) clasifican heurísticos y sesgos en siete grupos: representatividad, causalidad y atribución, disponibilidad, covariación y control, exceso de confianza, conservadurismo y sesgos en la percepción del riesgo. Más aún, distinguen otros cinco fenómenos: dependencia del encuadre, preferencias no lineales, dependencia de la fuente, propensión al riesgo y aversión a las pérdidas.

- Las principales clasificaciones de heurísticos incluyen a Gilovich y Griffin (2002), con seis heurísticos de uso general (afecto, disponibilidad, causalidad, fluidez, similitud y sorpresa) y seis de uso particular (prototipo, sustitución de atribuciones, reconocimiento, indignación, elección por gusto y elección por defecto), y Hens y Bachmann (2008), con cinco grupos de heurísticos: en la selección de información, en el procesamiento de información, en la toma de decisiones, en la evaluación de decisiones y en decisiones intertemporales.
- Los siguientes ofrecen un enfoque más integral de heurísticos y sesgos de juicio. Kahneman y Riepe (1998) distinguen heurísticos, errores de preferencia (*prospect theory*) y encuadre. Rabin (1998) distingue sesgos leves (p. ej., aversión a las pérdidas), graves (p. ej., sesgo confirmatorio) y evidencias en contra del modelo de utilidad (dependencia del encuadre, inversión de preferencias y autocontrol). Mullainathan y Thaler (2000) señalan tres tipos de desviaciones del modelo económico estándar (racionalidad limitada, fuerza de voluntad limitada e interés propio limitado). Camerer y Loewenstein (2004) enumeran juicios de probabilidad (p. ej., heurísticos) y preferencias (encuadre, anclaje, aversión a las pérdidas, puntos de referencia, inversión de preferencias y descuento hiperbólico). Trabajos más recientes distinguen preferencias, creencias y toma de decisiones no estándar (DellaVigna, 2009) o bien sesgos de juicio y de decisión (Hirshleifer, 2015).

- Finalmente, algunos autores han puesto de relieve también la influencia de factores grupales y sociales, atendiendo a efectos de contagio. Incluiríamos aquí a Shiller (2000a), quien enumera teorías de las ciencias sociales utilizadas en las finanzas, como *prospect theory*, contabilidad mental, arrepentimiento y disonancia cognitiva, y Akerlof y Shiller (2009), quienes señalan el papel de los «espíritus animales» como mecanismos de retroalimentación, justicia y contagio social.

Como resumen, y únicamente a modo ilustrativo, para facilitar al lector la familiarización con la multitud de sesgos que impregnan la toma de decisiones y desafían los postulados de las finanzas estándar, el cuadro n.º 1 proporciona un breve resumen de los principales sesgos de comportamiento, extraído a partir de Peón, Antelo y Calvo (2017).

## 2. Anomalías en los mercados financieros

Heurísticos, sesgos, creencias, preferencias atípicas y toma de decisiones sesgadas conducen a efectos a nivel individual, y anomalías en los mercados financieros —es decir, resultados empíricos difíciles de racionalizar bajo el paradigma tradicional (Kahneman, Knetsch y Thaler, 1991). De ello se deriva uno de los debates más controvertidos en las ciencias sociales: el de la eficiencia de los mercados financieros. Miles de artículos durante décadas han analizado el comportamiento de los precios de los activos financieros, pero seguimos sin alcanzar un consenso. La controversia alcanzó notoriedad pública cuando los padres de las dos visiones contrapuestas, Eugene Fama y Robert Shiller, compartieron el Premio Nobel de Economía el mismo año.

Tras la ausencia de consenso están dos aspectos de la hipótesis del mercado eficiente (*EMH*, por sus siglas en inglés). La primera, el uso de dos definiciones diferentes. Fama (1970) define como mercado eficiente aquel donde los precios de los activos reflejan toda la información de mercado disponible. De ella se deriva una interpretación alternativa que, sin embargo, no es necesariamente recíproca: en un mercado eficiente no es posible obtener beneficios superiores de manera sistemática haciendo uso de la información de mercado disponible (Jensen, 1978). La ausencia de reciprocidad es una crítica que se retrotrae a Shiller (1984): la impredecibilidad de la serie de precios de un activo no implica que los precios se formen de manera racional.



CUADRO N.º 1

## TAXONOMÍA DE SESGOS DE COMPORTAMIENTO

## Heurísticos y sesgos de juicio

Disponibilidad

Sesgo de atención

Sesgo retrospectivo

Principal heurístico de selección de información. Tendencia a estimar la probabilidad de un evento por la facilidad con la que se pueden rememorar los sucesos.

Representatividad

Sesgos de extrapolación

Grado de correspondencia entre un resultado y un modelo. Implica una tendencia a basarse en estereotipos, lo que lleva a estimar probabilidades basadas en creencias más que en la probabilidad.

Afecto

Risk-as-feelings

Etiquetamos objetos y eventos con diferentes grados de afecto. El heurístico genera intuiciones más rápidas que la memoria. Percibir el riesgo como sentimientos supone evaluar el riesgo como emoción, pudiendo diferir de la evaluación cognitiva.

Familiaridad

Aversión a la ambigüedad

El miedo al cambio, a lo desconocido, y la aversión a la ambigüedad conducen a decisiones sesgadas como el sesgo de *statu quo*, pobre diversificación y sesgo local

Excesivo optimismo

Sobre- (sub-) estimar la probabilidad de buenos (malos) resultados de sucesos sobre los que no tenemos control.

Exceso de confianza

Sobreestimar nuestras propias capacidades y éxito. Tres variantes: sobrevalorar nuestro desempeño (sobreestimación), sobrevalorarlo en relación a otros (mejor que la media), y precisión excesiva ante la incertidumbre (sobreprecisión).

## Toma de decisiones

Encuadre

Dependencia del encuadre

Contabilidad mental

El decisor concibe los actos, resultados y riesgos asociados a una elección. Lleva a cambios de preferencia cuando el encuadre cambia, o en función del método usado para codificar y evaluar transacciones, inversiones, etc. Implica la aceptación pasiva de la formulación dada, así como evaluar los beneficios o pérdidas de una inversión aislada en lugar de en el marco de la cartera de inversión.

Prospect theory

Puntos de referencia

Aversión a las pérdidas

Sensibilidad decreciente

Principal teoría descriptiva sobre la toma de decisiones en incertidumbre. El valor percibido depende de las ganancias o pérdidas respecto a un punto de referencia. Las pérdidas duelen más que la satisfacción por ganancias de la misma magnitud, y el valor marginal de ganancias y pérdidas disminuye con su tamaño.

Resulta un patrón cuádruple de actitudes frente al riesgo:

- aversión al riesgo ante ganancias probables, pero propensión al riesgo ante pérdidas altamente probables;
- propensión al riesgo ante ganancias poco probables, pero aversión al riesgo por las pérdidas de baja probabilidad.

Preferencias intertemporales

Inversión de preferencias

Sesgo presente

Mostramos preferencias inconsistentes en el tiempo, problemas para comprometerse con decisiones tomadas en el pasado, y preferencia por el presente.

## Factores grupales y sociales

Contagio

Comportamiento gregario

Ejemplos del contagio social son los inversores que siguen a gurús, revistas, discuten inversiones con otros inversores.... El pensamiento grupal es la tendencia de grupos de personas a llegar a un consenso sin considerar hipótesis alternativas.

Justicia y equidad

A menudo tomamos decisiones financieras en función de lo que consideramos un resultado justo o equitativo para las partes.

Avaricia y miedo

Factores emocionales que tienden a aparecer particularmente cuando los individuos interactúan entre sí, en mercados financieros y gestión de carteras, influyendo en la tolerancia al riesgo y determinando la selección de carteras de inversión.

Cascadas de información

Burbujas especulativas

Acontecimientos significativos de mercado ocurren a menudo solo si grandes grupos de inversores piensan igual. Redes sociales y medios de comunicación podrían ser vehículos para tal difusión de ideas.

Fuente: Elaboración propia a partir de Peón, Calvo y Antelo (2017).

## CUADRO N.º 2

## TESTS DE LA HIPÓTESIS DEL MERCADO EFICIENTE

## Predecibilidad de la rentabilidad a corto plazo

|                           |                                                                                |
|---------------------------|--------------------------------------------------------------------------------|
| Independencia estadística | Evidencia favorable al mercado eficiente en mercados desarrollados.            |
| Reglas de <i>trading</i>  | Habitualmente, los beneficios no exceden los costes de transacción.            |
| Efectos de calendario     | Los efectos suelen ser espúreos y tienden a desaparecer una vez identificados. |

## Predecibilidad de la rentabilidad a largo plazo

|                                                   |                                                                                                                                                                                                                                                                                                                                                             |
|---------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Volatilidad excesiva y reversión a la media       | Los mercados fluctúan mucho más de lo que sería de esperar por fundamentales. El tipo de descuento aplicado – la tasa marginal intertemporal de sustitución del consumo en el CAPM intertemporal – deviene el quid de la cuestión. Evidencia mixta sobre la capacidad del retorno por dividendo de predecir el exceso de rentabilidad ponderado por riesgo. |
| Sobrerreacción                                    | La rentabilidad de las estrategias “contrarias” se relaciona a menudo con un efecto tamaño. Evidencia mixta sobre la capacidad del retorno por dividendo y de la ratio MBV de predecir el exceso de rentabilidad ponderado por riesgo.                                                                                                                      |
| <i>Momentum</i>                                   | Evidencia de rentabilidad temporal de las estrategias basadas en el desempeño reciente. Para los economistas racionalistas, se atribuye a factores de riesgo económico que afectan a los ciclos de inversión y tasas de crecimiento empresarial. Los conductuales desarrollan modelos teóricos que explican que sobre- e infra- reacción pueden coexistir.  |
| Rentabilidad transversal ( <i>cross-section</i> ) | Evidencia favorable a los efectos tamaño y valor (PER y MBV).                                                                                                                                                                                                                                                                                               |

## Estudio de eventos

|                                                               |                                                                                                                                                                      |
|---------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Anuncio de resultados                                         | Evidencia mixta del impacto en el tiempo de la publicación de resultados ( <i>post-earnings announcement drift</i> ).                                                |
| Efectos de <i>trading</i> ( <i>splits</i> , indexación, etc.) | Interpretaciones contrapuestas sobre el efecto de <i>splits</i> y la racionalidad de la rentabilidad adicional proporcionada por la inclusión en índices bursátiles. |
| Eventos corporativos                                          | Evidencia frecuente de infravaloración en las OPVs.                                                                                                                  |

## Tests de eficiencia relativa

|                      |                                                                                                                                                                                                                                                                                                                                                              |
|----------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Ley del precio único | Productos idénticos deben tener precios idénticos en mercados diferentes. Rechazar la ley implica que el precio está sesgado en al menos un mercado. Las anomalías identificadas incluyen la cotización de fondos cerrados, de acciones gemelas, de escisiones corporativas ( <i>spin-offs</i> ) y en mercados de divisas ( <i>forward premium puzzle</i> ). |
|----------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|

## Test de información privilegiada

|                                     |                                                                                                                     |
|-------------------------------------|---------------------------------------------------------------------------------------------------------------------|
| Empresas ( <i>insider trading</i> ) | Difícil de contrastar, la mayor parte de los estudios refutan la hipótesis fuerte de eficiencia.                    |
| Inversores profesionales            | Amplia evidencia en favor de la hipótesis de mercado eficiente (analistas, gestores de inversores institucionales). |

Fuente: Elaboración propia a partir de Peón, Calvo y Antelo (2019).

La segunda razón se deriva del problema de la hipótesis conjunta. La *EMH*, por sí misma, no es una hipótesis bien definida y empíricamente refutable; únicamente tiene contenido empírico en el marco de un modelo de mercado en equilibrio (Fama, 1970). Por ello, cualquier test de la *EMH* implica también un test de las hipótesis auxiliares; si se refuta, puede deberse a que el modelo de valoración de activos empleado sea incorrecto, o alguno de los supuestos asumidos (aversión al riesgo, etc.) sean incorrectos.

Para ilustrar al lector en el estado del arte en la actualidad, y de nuevo sin ánimo de exhaustividad, en el cuadro n.º 2 se resumen los principales test de *EMH* extraídos a partir de Peón, Calvo y Antcló (2019), deudor a su vez de estudios clásicos como Fama (1991), Campbell, Lo y MacKinlay (1996), y Premio Nobel (2013).

En resumen, la mayor parte de la evidencia empírica en aspectos como los movimientos de la serie de precios a corto plazo o que los inversores profesionales rara vez superan al mercado de manera sistemática validan la hipótesis del mercado eficiente. En cambio, cuestiones como la racionalidad de la superioridad de estrategias como *momentum*, valor y tamaño continúan debatidas, y los resultados positivos en test de eficiencia relativa son una evidencia en contra de la eficiencia del mercado.

### III. SESGOS DE COMPORTAMIENTO Y MERCADOS DE CRÉDITO BANCARIO

Encauzamos ahora el artículo hacia su propósito principal: el análisis de los sesgos de comportamiento en los mercados de crédito, y su impacto en forma de auges de crédito y su eventual colapso. Para ello, analizaremos primero dos de sus fundamentos principales. Por un lado, veremos cuáles son los sesgos más utilizados en la literatura a la hora de modelizar, desde un punto de vista teórico, el impacto de la racionalidad limitada sobre el comportamiento de las entidades financieras. Por otro, comentaremos brevemente las teorías sobre la formación de burbujas de activos y de crédito.

#### 1. Fundamentos principales: optimismo y burbujas financieras

De manera más reciente, la *BF* ha empezado a extender su campo de análisis fuera de los merca-

dos financieros. Uno de los ámbitos más representativos es el que analiza la influencia de los sesgos de comportamiento en la toma de decisiones empresariales, entre las que se incluyen, claro está, las propias entidades financieras que otorgan crédito a empresas y particulares. La literatura conductual en los mercados de crédito ha seguido a menudo una línea similar al de la *behavioral corporate finance*. Aquí, los sesgos de comportamiento estudiados son, en general, similares a los vistos en la sección anterior –para un resumen de esta literatura, véase Shefrin (2006)–. Sin embargo, si hay un sesgo de comportamiento –o, mejor dicho, dos– sobre los que los autores han hecho especial énfasis son el excesivo optimismo y *over confidence* (exceso de confianza, *OC*) mostrados por los directivos y gestores de las entidades. Dos sesgos de comportamiento cercanos que a menudo se confunden; las personas con exceso de optimismo subestiman la probabilidad de malos resultados sobre los que no tienen control (Kahneman y Riepe, 1998), mientras que la *OC* se puede manifestar de tres formas (Moore y Healy, 2008): en la estimación de nuestro propio desempeño, en la estimación de nuestro desempeño en comparación a otras personas, y en una excesiva precisión en la estimación de la incertidumbre futura. Ambos sesgos se confunden desde el momento en que la *OC*, interpretado como una sobreestimación de las probabilidades de éxito empresarial, conduce a un exceso de optimismo sobre los resultados empresariales futuros.

Los análisis de los efectos sobre los resultados empresariales de las decisiones de ejecutivos excesivamente optimistas y con exceso de confianza son un tema recurrente en la literatura conductual (para una revisión, véase Malmendier y Tate, 2015). A modo ilustrativo, los efectos incluirían las altas tasas de fracaso empresarial (Camerer y Lovallo, 1999), de recompra de acciones (Shu et al., 2013) y de ofertas públicas de venta (OPV) observadas (Boulton y Campbell, 2016). Asimismo, explicarían sesgos en las decisiones de inversión (Malmendier y Tate, 2005 a y b) y la sensibilidad de la inversión al flujo de caja (Mohamed, Fairchild y Bouri, 2014). Por otro lado, optimismo y *OC* explicarían la tendencia a menores ratios de *payout* a la hora de distribuir dividendos (Deshmukh, Goel y Howe, 2013), la tendencia a una mayor tenencia de efectivo (Huang-Meier, Lambertides y Steeley, 2016), y efectos sobre las decisiones de inventario (Lu et al., 2015). Por último, algunos autores han identificado la relación entre estos sesgos de comportamiento y la tendencia a suavizar

ganancias (*earnings smoothing*, Bouwman, 2014) y otros, en cambio, con la tendencia a llevar una contabilidad menos conservadora (Ahmed y Duellman, 2013). Por último, un estudio clásico es el efecto de la OC sobre las altas tasas de adquisiciones corporativas que resultan no rentables, una literatura que comienza con Roll (1986) y culmina con Malmendier y Tate (2008).

En el epígrafe siguiente veremos varios modelos que se fundamentan en estos sesgos conductuales y, en particular, optimismo y OC, para explicar la formación de burbujas de crédito. Por ello, resumimos primero brevemente la literatura sobre burbujas financieras. Una burbuja es una desviación del precio de mercado con respecto al valor fundamental de dicho activo, un efecto producido porque buena parte de los inversores «persiguen la tendencia» de mercado, reaccionando a los cambios de precios pasados más que a la información de mercado (Shleifer, 2000). Tras ellas, por tanto, estaría la especulación, entendida como las decisiones tomadas por inversores que compran hoy activos a precios que superan sus propias valoraciones porque creen que podrán venderlos en el futuro a precios todavía más altos.

En los mercados de crédito, la interpretación más aceptada de cómo ocurren estas burbujas es, sin duda, la de Kindleberger (1978): un proceso desequilibrado autosostenido que comienza con buenas noticias para un activo, generando una ganancia en el mismo, al cual sigue un aumento tanto de la oferta como de la demanda del activo, alentada por los primeros inversores. De este modo, la burbuja se sostiene por la actuación de los mismos inversores que se benefician en la fase inicial, aumentando la oferta del activo al tiempo que atraen a otros inversores, de carácter más especulador, que buscan invertir en un activo de buen comportamiento reciente. El aumento de la demanda permite seguir impulsando el proceso alcista de los precios pese a que el activo cuenta cada vez con mayor oferta hasta que, eventualmente, el mercado termina por derrumbarse. Muchos autores sostienen que este es, en efecto, el proceso vivido en diversos países, previo a la crisis financiera de 2007, con la oferta de crédito hipotecario que retroalimenta el valor de las viviendas jugando el papel central.

La existencia de burbujas financieras representa un reto para los modelos tradicionales de valoración de activos. Las finanzas conductuales, en cambio, se apartan del supuesto de racionalidad, mostrando

que estos procesos se explican fácilmente con la presencia de sesgos de comportamiento por parte de los agentes del mercado. Scherbina (2013) clasifica estos modelos en cuatro categorías. En primer lugar, los modelos de diferencias de opinión muestran que el optimismo y el exceso de confianza, entre otros sesgos de comportamiento de los inversores, pueden fomentar la aparición de burbujas en mercados donde el arbitraje o la venta en corto no es posible (*p. ej.*, Scheinkman y Xiong, 2003). Como veremos, es el tipo más frecuente entre los modelos conductuales propuestos recientemente para explicar las burbujas de crédito bancario.

En segundo lugar, los modelos de *feedback trading* (negociación por retroalimentación) asumen que algunos inversores negocian basándose en movimientos pasados de los precios. Por ejemplo, los medios de comunicación amplificarían las tendencias de mercado influyendo en los inversores menos informados (Shiller, 2002), mientras que para los inversores racionales y mejor informados puede ser también menos arriesgado seguir las tendencias del mercado, comprando hoy activos que consideran sobrevalorados con la expectativa de venderlos más caros en el futuro, en lugar de realizar un arbitraje de riesgo (DeLong et al., 1990). Tercero, modelos basados en sesgos de confirmación: inversores que solamente reconocen aquellos hechos que confirman sus creencias, descartando aquellos que las contradicen (*p. ej.*, Daniel, Hirshleifer y Subrahmanyam, 1998). Cuarto, modelos basados en la representatividad (Tversky y Kahneman, 1982) para explicar sobrerreacciones y el sesgo conservador (Edwards, 1968) para explicar una reacción insuficiente. Un modelo clásico de este tipo sería Barberis, Shleifer y Vishny (1998).

## 2. Mercados de crédito bancario

Vemos ahora diversos modelos que explican cómo los sesgos conductuales estarían detrás de comportamientos ineficientes del sistema bancario en competencia (en esta sección), así como a lo largo de los ciclos de crédito (en la sección siguiente). Dado que la mayoría de ellos se han basado en OC y/o optimismo, vemos estos modelos primero. Pueden ser de dos tipos: aquellos donde las burbujas de crédito se generan por la presencia del sesgo en un agente representativo de la economía (modelos de demanda), o aquellos donde son los gestores de las entidades financieras quienes muestran los sesgos de comportamiento (modelos de oferta).

Entre los modelos conductuales centrados en la demanda, destaca Boz y Mendoza (2014). Los autores parten de la premisa de que la innovación financiera y el exceso de confianza en el riesgo de los nuevos productos financieros amplifican el ciclo crediticio, y fueron factores clave en la crisis de 2008 en EE.UU. Una innovación financiera caracterizada por nuevos instrumentos que titulizan los flujos de pago generados por distintos activos financieros, hipotecas sobre viviendas (*collateralized mortgage obligations, CMO*) y permutas de riesgo crediticio (*credit default swaps, CDS*). En el modelo, reconocer el riesgo real de estos instrumentos financieros requiere tiempo, y este proceso de aprendizaje interactúa con una restricción hipotecaria que limita la deuda de los hogares a no exceder una fracción del valor de mercado de sus propiedades residenciales:

$$\frac{b_{t+1}}{R} \geq -k_t q_t l_{t+1} \quad [1]$$

donde  $b_{t+1}$  establece el valor de la deuda de los hogares, que queda limitada –en términos negativos– a no caer por debajo de una fracción del valor de sus propiedades inmobiliarias ( $q_t$  es el precio del suelo, y  $l_{t+1}$  el suelo disponible). La fracción la establece  $k_t$ , variable que sigue un proceso estocástico de Markov a través del cual los agentes aprenden cuál es el verdadero riesgo de las innovaciones financieras. El optimismo de los agentes les hace asignar mayor probabilidad a precios más altos de los activos y una mayor deuda, y lo contrario ocurre cuando son pesimistas. Este proceso conduce a un período de auge del crédito y del precio de la vivienda, seguido de un colapso repentino. A largo plazo, el modelo converge a la solución de expectativas racionales, pero a corto plazo, el crédito y los precios de los activos se desvían del equilibrio racional, porque las creencias sesgadas de los agentes conducen a una valoración errónea del riesgo.

Otros modelos de demanda similares son los de Perrero (2012), quien analiza los efectos de relajar los requisitos de la ratio préstamo-valor (*loan-to-value, LTV*), y Howitt (2017), quien estudia la interacción de expectativas, endeudamiento, y una restricción de solvencia en un modelo de agente representativo.

Nos centramos ahora en los modelos de oferta: aquellos en los que son los directivos de (algunas) entidades financieras quienes muestran los sesgos de comportamiento. Alimentados por optimismo y OC, y con la imposibilidad –por definición en los

mercados de crédito bancario– de que se establezcan mecanismos de arbitraje o realizar ventas en corto, estos modelos se englobarían en el primer grupo de burbujas, definidos por Scherbina (2013), descritos anteriormente.

La primera propuesta teórica la realiza Tobias Rotheli (2012a). El autor destaca que, a pesar de la abundante evidencia empírica sobre competencia imperfecta en el mercado de crédito (Bikker y Haaf, 2002), no existe a la fecha un modelo teórico ampliamente aceptado. Propone un modelo de competencia oligopolística entre bancos que conecta los sesgos de comportamiento individuales de algunos bancos –optimismo o pesimismo sobre las expectativas de impago de los prestatarios– con los períodos de auge y contracción del crédito. El modelo se basa en la literatura de competencia espacial (Capozza y Van Order, 1978), donde los bancos establecen el tipo de interés de los préstamos a ofertar a potenciales prestatarios situados entre ellos, y el coste percibido por el cliente suma a dicho tipo de interés un coste de desplazamiento proporcional a la distancia al banco. En el caso más simple, para dos entidades financieras y un cliente a una distancia  $d_A$  del primero de ellos, el coste del crédito sería:

$$r_A = i_A + cd_A \quad y \quad r_B = i_B + c(1 - d_A). \quad [2]$$

Minimizando los costes del crédito se determina el segmento de mercado que cubrirá cada entidad. Al introducir la posibilidad de que una proporción –entre el 0 por 100 y el 100 por 100– de las entidades financieras del sector sobreestimen el riesgo de impago (pesimismo) o lo subestimen (optimismo), el crédito concedido es menor en el primer caso, y mayor en el segundo, respecto al escenario en el que ningún banco muestra sesgos conductuales. Lo relevante del modelo es la predicción de que la simple presencia de una minoría de bancos sesgados –en torno al 25 por 100 del mercado– es suficiente para obtener resultados extremos, tanto de auge de crédito (optimismo) como de contracción (pesimismo) –véase gráfico 2 en la sección siguiente–.

Peón, Calvo y Antelo (2015a) y Peón y Antelo (2018b) parten de un modelo simplificado de competencia bancaria donde el único negocio bancario es el de intermediación, no tienen restricciones de liquidez, tienen acceso a un volumen ilimitado de depósitos, el banco central no impone reservas, y no se consideran los posibles efectos de una



quiebra. Una versión simplificada de los modelos propuestos sería:

$$\left. \begin{aligned} \max \Pi^i(L^i) &= \theta^i r (L^i + L^{i*}) L^i - d D^i - c L^i J \\ \text{s.t.: } L^i &= D^i \end{aligned} \right\} \quad [3]$$

para cada banco  $i$ , donde  $j^*$  define la estrategia de la competencia en el equilibrio,  $\Pi$  son los beneficios a maximizar,  $L$  el volumen de crédito concedido,  $r$  el tipo de interés de los préstamos concedidos,  $d$  el coste de los depósitos, y  $c$  los costes unitarios de la función de costes de la entidad financiera. Cuando se introduce la posibilidad de que algunos bancos sean excesivamente optimistas respecto de la probabilidad de impago de los prestatarios ( $1 - \theta$ ), tal que  $0 < \theta < \theta^* < 1$ , el modelo determina que la competencia asimétrica entre racionales y sesgados amplifica el *boom* crediticio, ya que los bancos excesivamente optimistas siempre otorgan más crédito, y los racionales, siempre que el sesgo del competidor no sea excesivamente alto, replican el mismo comportamiento (*herding*) para no perder cuota de mercado. Por último, empleando un modelo similar, Peón y Antelo (2018a) analizan los efectos de la concentración bancaria. Se comprueba que una fusión entre dos bancos racionales podría, en algunos escenarios, modificar su comportamiento de manera que, tras la fusión, les resultase conveniente imitar el comportamiento más agresivo del banco sesgado cuando, antes de la fusión, no habrían actuado así. El modelo sugiere, por tanto, los riesgos de una excesiva concentración bancaria en una industria expuesta a los sesgos de optimismo y OC.

Los modelos conductuales a partir de otros sesgos que no sean optimismo/OC son más escasos. Entre ellos, destacaríamos dos. Burakov (2016) propone un modelo donde los riesgos que asumen las entidades financieras dependen del sesgo de disponibilidad y de la experiencia de sus empleados. Obtiene evidencia experimental de que, tras un *shock* inicial de impagos, el número de períodos necesario para aceptar un nivel de riesgo similar se incrementaba un 39 por 100. Favilukis, Ludvigson y Van Nieuwerburgh (2017) analizan los efectos macroeconómicos de la riqueza inmobiliaria y la financiación hipotecaria en un modelo de equilibrio general dinámico estocástico (DSGE, por sus siglas en inglés) con agentes heterogéneos y restricciones de crédito. El modelo se basa en la relajación, en un momento dado, de las restricciones de garantía hipotecaria impuestas por el sector bancario, si

bien no se sugiere cuál es el supuesto explícito de tipo conductual tras esta decisión. Como resultado, los precios de los activos inmobiliarios se disparan, al elevarse la ratio precio/utilidad marginal ( $P/UM$ ) de la vivienda (2). El resultado es una burbuja de precios de la vivienda como consecuencia de la reducción de la prima de riesgo inmobiliaria, no de la reducción de tipos de interés.

#### IV. LOS CICLOS DE CRÉDITO BANCARIO

Conforme a los modelos revisados en la sección anterior, la BF muestra el impacto de los sesgos de comportamiento en los mercados de crédito. Sin embargo, estos sesgos son muy variados, y es de suponer que muchos de ellos actúen en direcciones opuestas. Es decir, algunas personas muestran exceso de confianza y optimismo de la misma manera que hay agentes pesimistas (*underconfident*, UC). Algunos son propensos a decisiones arriesgadas igual que otros son aversos al riesgo. Y, *a priori*, podríamos esperar un comportamiento gregario tanto en un sentido como en otro. Por ello, ¿no sería de esperar que unos sesgos conductuales se cancelen con otros en un mercado competitivo?

De hecho, existen modelos plausibles que explican la crisis crediticia sin necesidad de asumir sesgos de comportamiento. Entre otros, los basados en el papel jugado por los incentivos ofrecidos a los consejeros delegados de las entidades financieras (Fahlenbrach y Stulz, 2011), o la evidencia de que las titulizaciones redujeron el esfuerzo de la banca para seleccionar correctamente a los prestatarios (Keys et al., 2010), con tasas de impago un 10 por 100-25 por 100 superiores para los grupos con mayor facilidad de ser titulizados respecto a carteras de riesgo similar. También, el riesgo moral asumido por los bancos (Acharya y Naqvi, 2012), cuando las entidades con acceso a liquidez en abundancia compensan a sus empleados en función del volumen de préstamos concedidos, induciendo una mayor asunción de riesgo. O la desregulación de los préstamos predatorios en EE.UU. (Di Maggio y Kermani, 2017; Mian y Sufi, 2018), tras evitar las autoridades americanas que las leyes contra estas actividades aplicasen a entidades que operen a nivel supraestatal, resultando en un incremento sustancial del crédito hipotecario concedido por ellas en 2005 y 2006.

Sin embargo, la principal virtud de los modelos conductuales estriba en mostrar una debilidad inherente al sector bancario. No es necesario asumir un

mal comportamiento de los agentes para explicar la crisis; simplemente, sesgos de comportamiento naturales llevan a agudizar los ciclos de crédito. Por un lado, requiere un supuesto poco restrictivo, ya que la psicología ha comprobado la frecuencia de estos sesgos a nivel individual, y solo se requiere su presencia en una parte del mercado. Por otro lado, y dando respuesta a nuestra pregunta anterior, los modelos teóricos sugieren que el impacto de los sesgos conductuales sobre el crédito evoluciona cíclicamente, tanto porque los propios sesgos evolucionan a lo largo del ciclo de una manera predecible como porque la presión competitiva lleva a los bancos racionales a comportarse de manera similar a los sesgados en determinadas circunstancias. Veamos estos dos aspectos separadamente.



Varios autores han modelizado la evolución de los sesgos a lo largo del ciclo. Así, Rotheli (2012b) asume que la banca actualiza de manera bayesiana sus expectativas sobre la situación del ciclo económico, pero estiman las probabilidades de transición de una fase de crecimiento a otra de recesión y viceversa a partir de un período de experiencia pasado limitado. Calibrando sus simulaciones a partir de los datos de la economía de EE.UU. entre 1945 y 2009, según el cual la duración media de un ciclo económico es de setenta meses (cincuenta y nueve de crecimiento y once de recesión), obtiene un impacto significativo del aprendizaje con racionalidad limitada de la banca sobre su percepción de la morosidad prevista por sus clientes. En concreto, los bancos se vuelven demasiados optimistas durante

el ciclo alcista, estimando un riesgo de impago inferior durante tres a cinco años, mientras que, en recesión, la sobrevaloración del riesgo comienza a pocos trimestres de comenzar el cambio de ciclo. Por otro lado, el proceso de aprendizaje empleado por Boz y Mendoza (2014) sigue el enfoque de Cogley y Sargent (2008), aplicando un proceso estocástico de Markov para describir el modo en que los agentes llegan a conocer el perfil del riesgo de crédito: tasas bajas de morosidad iniciales llevan al optimismo sobre la probabilidad de persistencia de este régimen, generando un auge en el crédito, hasta que los primeros impagos conducen al pesimismo y a la caída del crédito.

En cuanto al impacto de esta evolución cíclica de los sesgos conductuales sobre el crédito concedido en un mercado competitivo, los modelos de oferta llegan a conclusiones distintas. Así, Rotheli (2012a y b) y Burakov (2016) predicen que los sesgos pesimistas amplifican el ciclo crediticio también en recesión. En el primer caso, porque el impacto del optimismo conduce al porcentaje de bancos que muestran racionalidad limitada en la industria a conceder excesivo crédito durante la fase de expansión, de la misma manera que les lleva a contraer el crédito concedido en recesión, amplificando el ciclo en ambos sentidos en comparación con lo que sería de esperar con un comportamiento racional. En el segundo, de manera similar, porque la prociclicidad de la política crediticia de la banca comercial es consecuencia de su limitado horizonte de memoria. Esto lleva a la formación de tendencias

GRÁFICO 2

## LOS CICLOS DE CRÉDITO BANCARIO EN LOS MODELOS DE OFERTA



Fuentes: Elaboración propia a partir de Rotheli (2012a) y Peón, Antelo y Calvo (2015b).

donde el conjunto de la banca subestima los riesgos en las fases favorables del ciclo, y los sobreestima en recesión.

En cambio, Peón, Antelo y Calvo (2015b) obtienen un resultado distinto. Partiendo de la modelización bayesiana, propuesta por Rotheli, de la evolución de los sesgos *OC* y *UC* a lo largo del ciclo, se obtiene en cambio una asimetría en el impacto de los sesgos de comportamiento: los bancos racionales seguirían a los optimistas en un ciclo alcista, pero no a los pesimistas en un ciclo bajista. La conclusión principal es que las burbujas de crédito las genera el exceso optimismo inicial, mientras que la caída del crédito posterior es consecuencia de la crisis de solvencia de las entidades, no del pesimismo. Más aún, el modelo anticipa que los nichos de peor calidad (mercados *subprime*) son los más sensibles a la presencia de sesgos de comportamiento. El gráfico 2 compara los resultados obtenidos por Rotheli (2012a) a la izquierda, y Peón, Antelo y Calvo (2015b) a la derecha.

## V. CONCLUSIONES PARA LA INDUSTRIA Y LOS REGULADORES

La gestión de la información ha sido y es un elemento central en el negocio bancario. Sin embargo, y pese a todo el conocimiento acumulado en el campo de la economía de la información, es un ámbito con importantes retos de futuro. En este artículo nos hemos centrado en el papel que los sesgos de comportamiento, identificados en décadas de investigación en la rama de las finanzas conductuales, tienen sobre la amplificación de los ciclos de crédito bancario.

Los principales modelos teóricos de la literatura conductual analizan el impacto de la racionalidad limitada de los agentes económicos (modelos de demanda) o de las propias entidades financieras (modelos de oferta) en la formación de burbujas de crédito. El tipo más frecuente de anomalía observada es la combinación de un sesgo optimista y la ausencia de posibilidades de arbitraje para la banca racional, que conduce a un exceso de crédito concedido por la industria. En los modelos de demanda, reconocer el riesgo real de las innovaciones financieras, como las titulizaciones hipotecarias, requiere tiempo, lo cual conduce a los agentes a amplificar el ciclo crediticio. En los modelos de oferta, son los directivos de algunas entidades financieras quienes muestran distintos sesgos de comportamiento (principalmente, optimismo/pesi-

mismo, exceso o defecto de confianza, disponibilidad y memoria limitada). Ello conduce igualmente a la amplificación del ciclo crediticio, siendo estos resultados robustos a distintas modelizaciones de la competencia bancaria (competencia espacial, competencia oligopolística y economía institucional).

Podemos destacar tres conclusiones relevantes. Primera, todos los modelos conductuales propuestos confirman el impacto sistemático de los sesgos optimistas en las fases alcistas del ciclo a la hora de amplificar el auge del crédito. El resultado en fases recesivas sería consecuencia de una solvencia bancaria deteriorada por los excesos del pasado, posiblemente agudizada por el impacto de sesgos pesimistas. Segunda, algunos modelos anticipan que los nichos de peor calidad (mercados *subprime*) son los más sensibles a la presencia de sesgos de comportamiento. Tercera, a pesar de que los procesos de consolidación bancaria tienen su fundamento, una excesiva concentración bancaria puede ser cuestionable si hace al mercado más sensible a los sesgos de algunas entidades.

Todo ello contribuye a identificar importantes implicaciones a nivel regulatorio. Una industria bancaria de exquisito funcionamiento estaría, aun así, expuesta a los sesgos de comportamiento en algunas de sus entidades, en particular si el grado de concentración bancaria es muy elevado. Esto supone una debilidad inherente al sector. No es necesario asumir un mal comportamiento de los agentes para explicar la crisis; simplemente, sesgos naturales como un excesivo optimismo en fases alcistas del ciclo económico llevan a amplificar el crédito concedido en el auge, y las restricciones en recesión.

Es razonable pensar que el impacto de los sesgos de comportamiento sea más importante en la industria bancaria que en otras. Mientras que, por ejemplo, un ganadero no conseguirá incrementar la producción láctea de su explotación simplemente porque sea más optimista respecto a las ventas futuras de su empresa, un banco concediendo crédito sí que puede hacerlo: solo tiene que ser más laxo a la hora de conceder crédito. Junto a ello, los modelos propuestos evidencian la facilidad con que «las manzanas podridas contaminan el cesto». En algunas circunstancias, los bancos racionales también se ven arrastrados a un comportamiento sesgado en la concesión de crédito debido a la presión competitiva, principalmente cuando no les interesa perder cuota de mercado frente a los excesivamente opti-

mistas, ya que el arbitraje en la industria bancaria es inviable.

Cabe señalar, en cualquier caso, que las limitaciones de los modelos conductuales revisados son numerosas, y requieren mayor contraste en futuras investigaciones. En primer lugar, existe una excesiva vinculación de estos modelos matemáticos al sesgo de exceso de optimismo o confianza. La razón principal es que es un sesgo más fácil de modelizar, fácilmente trasladable a un impacto en términos de la probabilidad de impago anticipada por la banca. Pero lo cierto es que los sesgos de comportamiento son mucho más numerosos, y su interacción más compleja. Tendría especial interés, de hecho, profundizar en el estudio de los sesgos colectivos, particularmente por sus implicaciones a nivel regulatorio: en la toma de decisiones por parte de los consejos de administración de las entidades financieras, así como en el intercambio de información entre reguladores y sistema bancario, ¿qué sesgos colectivos pueden resultar perniciosos? ¿Qué mecanismos moderadores se pueden establecer?

Además, estos modelos asumen versiones simplificadas del funcionamiento de la industria bancaria y del sistema financiero. En la mayor parte de los casos se consideran bancos de tamaño similar, ausencia de mercado interbancario, se obvian los costes de una eventual quiebra, etc. Sería interesante, de hecho, explorar en el marco de estos modelos cuál sería el efecto sobre el comportamiento previsto por las entidades de un impacto asimétrico de la morosidad bancaria que afectase a los bancos menos solventes, así como el resultado a nivel industria tras la quiebra o reordenación de algunas entidades. Por último, resulta especialmente reseñable la escasa evidencia empírica ofrecida para respaldar los modelos teóricos. Si bien la realización de contrastes empíricos resulta en este caso más compleja, a nivel experimental apenas se pueden destacar los trabajos de Peón, Antelo y Calvo (2016) y Burakov (2016).

Con todo, y pese a las limitaciones, el interés de los modelos es evidente, y los resultados formulados sugieren un amplio campo de investigación por delante.

#### NOTAS

(1) Como nota al margen, señalar que, obviamente, también existe una interpretación alternativa que sugiere que las burbujas serían una respuesta racional del mercado. FAMA y FRENCH (1988) subrayan que las oscilaciones temporales de las cotizaciones bursátiles no implican necesariamente burbujas irracionales: un componente de los precios con

reversión lenta a la media sería la responsable de inducir una autocorrelación negativa de los rendimientos durante largos períodos, pero una autocorrelación débil durante períodos diarios o semanales. Además, las burbujas irracionales son indistinguibles del efecto que provocan rendimientos esperados que varían en el tiempo (FAMA, 1991). Los experimentos de SMITH, SUCHANEK y WILLIAMS (1988) y siguientes vierten dudas sobre esta interpretación, ya que los participantes recibían toda la información precisa para calcular los valores fundamentales, pero en la mayoría de los experimentos los precios subieron muy por encima de su valor fundamental. Pese a ello, algunos experimentos posteriores matizan estos resultados, como la evidencia de que introducir un mercado de futuros reduce el número de ineficiencias observadas (PORTER y SMITH, 1995), o cómo introducir jugadores con experiencia previa en el experimento –equivalente en la práctica a contar con inversores más experimentados– reducía o llegaba a hacer desaparecer las burbujas de precios (DUFWENBERG, LINDQVIST y MOORE, 2005).

(2) Los autores miden la ratio de utilidad para una economía doméstica como la relación entre la utilidad marginal de la vivienda y el flujo de consumo no relacionado con la vivienda. La ratio  $P/UM$  divide el índice general de precios de la vivienda por el agregado de dichas utilidades marginales para todas las economías domésticas.

#### BIBLIOGRAFÍA

- ACHARYA, V. y NAQVI, H. (2012). The seeds of a crisis: a theory of bank liquidity and risk taking over the business cycle. *Journal of Financial Economics*, 106(2), pp. 349-366.
- AHMED, A. S. y DUELLMAN, S. (2013). Managerial overconfidence and accounting conservatism. *Journal of Accounting Research*, 51(1), pp. 1-30.
- AKCROF, G. A. y SHILLER, R. J. (2009). *Animal Spirits: How Human Psychology Drives the Economy, and Why It Matters for Global Capitalism*. Princeton University Press.
- BARBERIS, N., SHLEIFER, A. y VISHNY, R. (1998). A model of investor sentiment. *Journal of Financial Economics*, 49(3), pp. 307-343.
- BCE (2012). *ECB Euro area bank lending survey*. Disponible en (último acceso sept-2019): <https://www.ecb.europa.eu/stats/money/surveys/lend/htmlindex.en.html>
- BIKKER, J. A. y HAAFF, K. (2002). Measures of competition and concentration in the banking industry: a review of the literature. *Economic & Financial Modelling*, Summer 2002, p. 1-46. Disponible en (último acceso sept-2019) [https://www.dnb.nl/binaries/Measurespor10020Competition\\_tcm46-145799.pdf](https://www.dnb.nl/binaries/Measurespor10020Competition_tcm46-145799.pdf)
- BOULTON, T. J. y CAMPBELL, T. C. (2016). Managerial confidence and initial public offerings. *Journal of Corporate Finance*, 37, pp. 375-392.
- BOUWMAN, C. H. S. (2014). Managerial optimism and earnings smoothing. *Journal of Banking & Finance*, 41, pp. 283-303.
- BOZ, E. y MENDOZA, E. G. (2014). Financial innovation, the discovery of risk, and the U.S. credit crisis. *Journal of Monetary Economics*, 62, pp. 1-22.
- BURAKOV, D. (2016). Retesting the institutional memory hypothesis: An experimental study. *Panoeconomicus*,



2016 OnLine-First Issue 00, Pages: 3-3. Doi:10.2298/PAN160105003B

- CAMERER, C. F. y LOEWENSTEIN, G. (2004). Behavioral Economics: Past, present, future. En C. F. CAMERER, G. LOEWENSTEIN y M. RABIN (eds.), *Advances in Behavioral Economics*, pp. 3-51. Princeton University Press.
- CAMERER, C. F. y LOVALLO, D. (1999). Overconfidence and excess entry: An experimental approach. *The American Economic Review*, 89, pp. 306-318.
- CAMPBELL, J. Y., LO, A. W. y MACKINLAY, A. C. (1996). *The econometrics of financial markets*. Princeton: Princeton University Press.
- CAPOZZA, D. R. y VAN ORDER, R. (1978). A generalized model of spatial competition. *American Economic Review*, 68(5), pp. 896-908.
- CARBÓ-VALVERDE, S., RODRIGUEZ-FEMÁNDEZ, F., UDELL, G. F. (2016). Trade credit, the financial crisis, and SME access to finance. *Journal of Money, Credit and Banking*, 48(1), pp. 113-143.
- COGLEY, T. y SARGENT, T. J. (2008). The market Price of risk and the equity premium: A legacy of the Great Depression? *Journal of Monetary Economics*, 55, pp. 454-478.
- DANIEL, K. D., HIRSHLEIFER, D. y SUBRAHMANYAM, A. (1998). Investor psychology and security market under- and overreactions. *The Journal of Finance*, 53(6), pp. 1839-1885.
- DELLA VIGNA, S. (2009). Psychology and Economics: Evidence from the field. *Journal of Economic Literature*, 47(2), pp. 315-372.
- DE LONG, J. B., SHLEIFER, A., SUMMERS, L. y WALDMANN, R. J. (1990). Positive feedback investment strategies and destabilizing rational speculation. *Journal of Finance*, 45, pp. 379-395.
- DESHMUKH, S., GOEL, A. M. y HOWE, K. M. (2013). CEO Overconfidence and Dividend Policy. *Journal of Financial Intermediation*, 22(3), pp. 440-463.
- DI MAGGIO, M. y KERMANI, A. (2017). Credit-induced boom and bust. *Review of Financial Studies*, 30(11), pp. 3711-3758.
- DUFWENBERG, M., LINDQVIST, T. y MOORE, E. (2005). Bubbles and experience: An experiment. *American Economic Review*, 95(5), pp. 1731-1737.
- EDWARDS, W. (1968). Conservatism in human information processing. Reprinted short version in D. KAHNEMAN, P. SLOVIC y A. TVERSKY (1982), *Judgment Under Uncertainty: Heuristics and Biases*. Cambridge University Press.
- FAHLENBRACH, R. y STULZ, R. M. (2011). Bank CEO incentives and the credit crisis. *Journal of Financial Economics*, 99(1), pp. 11-26.
- FAMA, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *Journal of Finance*, 25(3), pp. 383-417.
- (1991). Efficient capital markets: 11. *The Journal of Finance*, 46(5), pp. 1575-1617.
- FAMA, E. F. y FRENCH, K. R. (1988). Permanent and temporary components of stock prices. *Journal of Political Economy*, 96, pp. 246-273.
- FAVILUKIS, J., LUDVIGSON, S. C. y VAN NIEUWERBURGH, S. (2017). The macroeconomic effects of housing wealth, housing finance, and limited risk-sharing in General Equilibrium. *Journal of Political Economy*, 125(1), pp. 140-223.
- FERRANDO, A., POPOV, A. y UDELL, G. F. (2017). Sovereign stress and SMEs' access to finance: Evidence from the ECB's SAFE survey. *Journal of Banking and Finance*, 81, pp. 65-80.
- FERRERO, A. (2012). House price booms, current account deficits, and low interest rates. Federal Reserve Bank of New York Staff Reports. *Technical Report 541*.
- FMI (2012). Spain - Financial system stability assessment. *Country Report No 12/137*. International Monetary Fund. Disponible en <http://www.imf.org/external/pubs/ft/scr/2012/cr12137.pdf>
- FRANKFURTER, G. M., MCGOUN, E. G. y ALLEN, D. E. (2004). The prescriptive turn in Behavioral Finance. *Journal of Socio-Economics*, 33, pp. 449-468.
- GARCÍA-APPENDINI, E. y MONTORIOL-GARRIGA, J. (2013). Firms as liquidity providers: Evidence from the 2007-2008 financial crisis. *Journal of Financial Economics*, 109(1), pp. 272-291.
- GILOVICH, T. y GRIFFIN, D. (2002). Introduction- Heuristics and Biases: Then and now. En T. GILOVICH, D. GRIFFIN y D. KAHNEMAN (eds.), *Heuristics and biases: The psychology of intuitive judgment*. Cambridge University Press.
- HENS, T. y BACHMANN, K. (2008). *Behavioral Finance for Private Banking*. John Wiley & Sons.
- HIRSHLEIFER, D. (2015). Behavioral Finance. *Annual Review of Financial Economics*, 7(7), pp. 133-159.
- HOWITT, P. (2017). Learning, leverage and stability. *International Journal of Computational Economics and Econometrics*, 7(3), pp. 265-279.
- HUANG-MEIER, W., LAMBERTIDES, N. y STEELEY, J. M. (2016). Motives for corporate cash holdings: the CEO optimism effect. *Review of Quantitative Finance and Accounting*, 47, pp. 699-732.
- JENSEN, M. C. (1978). Some anomalous evidence regarding market efficiency. *Journal of Financial Economics*, 6, pp. 95-101.
- KAHNEMAN, D., KNETSCH, J. L. y THALER, R. H. (1991). Anomalies: The endowment effect, loss aversion, and status quo bias. *The Journal of Economic Perspectives*, 5(1), pp. 193-206.
- KAHNEMAN, D. y RIEPE, M. (1998). Aspects of investor psychology. *Journal of Portfolio Management*, 24, pp. 52-65.



- KAHNEMAN, D., SLOVIC, P. y TVERSKY, A. (1982). *Judgment Under Uncertainty: Heuristics and Biases*. Cambridge University Press.
- KEYS, B. J., MUKHERJEE, T., SERU, A. y VIG, V. (2010). Did securitization lead to lax screening? Evidence from subprime loans. *Quarterly Journal of Economics*, 125(1), pp. 307-362.
- KINDLEBERGER, C. P. (1978). *Manias, Panics and Crashes: A History of Financial Crises*. New York: Palgrave Macmillan. Sixth edition, 2011.
- LU, X., SHANG, J., WU, S., HEGDE, G. G., VARGAS, L. y ZHAO, D. (2015). Impacts of supplier hubris on inventory decisions and green manufacturing endeavors. *European Journal of Operational Research*, 245, pp. 121-132.
- MALMENDIER, U. y TATE, G. (2005a). CEO overconfidence and corporate investment. *Journal of Finance*, 60, pp. 2661-2700.
- (2005b). Does overconfidence affect corporate investment? CEO overconfidence measures revisited. *European Financial Management*, 11(5), pp. 649-659.
- (2008). Who makes acquisitions? CEO overconfidence and the market's reaction. *Journal of Financial Economics*, 89, pp. 20-43.
- (2015). Behavioural CEOs: The role of managerial overconfidence. *Journal of Economic Perspectives*, 29(4), pp. 37-60.
- MAREWSKI, J. N., GAISSMAIER, W. y GIGERENZER, G. (2010). Good judgments do not require complex cognition. *Cognitive Processing*, 11(2), pp. 103-121.
- MCGUINNESS, G. y HOGAN, T. (2016). Bank credit and trade credit: Evidence from SMEs over the financial crisis. *International Small Business Journal*, 34(4), pp. 412-445.
- MIAN, A. y SUFI, A. (2018). Finance and business cycles: The credit-driven household demand channel. *Journal of Economic Perspectives*, 32(3), pp. 31-58.
- MOHAMED, E. B., FAIRCHILD, R. y BOURI, A. (2014). Investment cash flow sensitivity under managerial optimism: New evidence from NYSE panel data firms. *Journal of Economics, Finance and Administrative Science*, 19, pp. 11-18.
- MOORE, D. A. y HEALY, P. J. (2008). The trouble with overconfidence. *Psychological Review*, 115, pp. 502-517.
- MULLAINATHAN, S. y THALER, R. H. (2000). Behavioral Economics. MIT Dept. of Economics Working Paper No. 00-27. Disponible en (último acceso sept-2019) SSRN: <http://ssrn.com/abstract=245828>
- PEÓN, D. (2015). *Behavioral microfoundations of retail credit markets: A theoretical and experimental approximation*. [Tesis Doctoral], Universidade da Coruña.
- PEÓN, D. y ANTELO, M. (2018a). Mergers in financial services and overlending. *Cuadernos de Economía*, 41(116), pp. 167-180.
- (2018b). Do bad borrowers hurt good borrowers? A model of biased banking competition. *Portuguese Economic Journal* 18(1), pp. 5-17. DOI: 10.1007/s10258-018-0149-1
- PEÓN, D., ANTELO, M. y CALVO, A. (2015b). A dynamic behavioral model of the credit boom. *Journal of Economic Issues*, 49(4), pp. 1077-1099. DOI: 10.1080/00213624.2015.1105043
- (2016). Overconfidence and risk seeking in credit markets: An experimental game. *Review of Managerial Science*, 10(3), pp. 511-552, DOI: 10.1007/s11846-015-0166-8
- (2017). A inclusive taxonomy of behavioral biases. *European Journal of Government and Economics*, 6(1), pp.24-58.
- PEÓN, D., CALVO, A. y ANTELO, M. (2015a). On informational efficiency of the banking sector: A behavioral model of the credit boom. *Studies in Economics and Finance*, 32(2), pp. 158-180. DOI: 10.1108/SEF-04-2013-0050
- (2019). A guide on empirical tests of the EMH. *Review of Accounting and Finance*, 18(2), pp. 268-295. DOI: 10.1108/RAF-02-2016-0031
- PORTER, D. P. y SMITH, V. L. (1995). Futures contracting and dividend uncertainty in experimental asset markets. *Journal of Business*, 68(4), pp. 509-541.
- PREMIO NOBEL (2013). The Prize in Economic Sciences 2013 - Advanced Information. *Nobelprize.org*, Nobel Media AB2013. Disponible en (último acceso sept-2019) [http://www.nobelprize.org/nobel\\_prizes/economic-sciences/laureates/2013/advanced.html](http://www.nobelprize.org/nobel_prizes/economic-sciences/laureates/2013/advanced.html)
- RABIN, M. (1998). Psychology and Economics. *Journal of Economic Literature*, 36(1), pp. 11-46.
- ROLL, R. (1986). The hubris hypothesis of corporate takeovers. *Journal of Business*, 59(2), pp. 197-216.
- ROTHEL, T. F. (2012a). Oligopolistic banks, bounded rationality, and the credit cycle. *Economics Research International*, volume 2012, Article ID 961316, 4 p.
- (2012b). Boundedly rational banks' contribution to the credit cycle. *Journal of Socio-Economics*, 41(5), pp. 730-737.
- SCHEINKMAN, J. A. y XIONG, W. (2003). Overconfidence and speculative bubbles. *Journal of Political Economy*, 111(6), pp. 1183-1219.
- SCHERBINA, A. (2013). Asset price bubbles: A selective survey. *IMF Working Paper WP/13/45*. Disponible en (último acceso sept-2019) <http://www.imf.org/external/pubs/ft/wp/2013/wp1345.pdf>
- SHEFRIN, H. (2006). *Behavioral Corporate Finance*. McGraw-Hill.
- SHILLER, R. J. (1984). Stock prices and social dynamics. *Brookings Papers on Economic Activity*, 2, pp. 457-498.

- (2000a). Human behavior and the efficiency of the financial system. En B. TAYLOR, y M. WOODFOOD (eds.), *Handbook of Macroeconomics*. Amsterdam: North Holland.
- (2000b). *Irrational exuberance*. Princeton University Press.
- (2002). Bubbles, human judgment, and expert opinion. *Financial Analysts Journal*, 58(3), pp. 18-26.
- SHLEIFER, A. (2000). *Inefficient Markets: An Introduction to Behavioral Finance*. Oxford University Press.
- SHU, P., YEH, Y., CHIANG, T. y HUNG, J. (2013). Managerial overconfidence and share repurchases. *International Review of Finance*, 13(1), pp. 39-65.
- SIMON, H. A. (1957). *Models of Man: Social and Rational*. Wiley.
- SMITH, V. L., SUCHANEK, G. L. y WILLIAMS, A.W. (1988). Bubbles, crashes, and endogenous expectations in experimental spot asset markets. *Econometrica*, 56(5), pp. 1119-1151.
- TVERSKY, A. y KAHNEMAN, D. (1982). Judgments of and by representativeness. En D. KAHNEMAN, P. SLOVIC y A. TVERSKY, (eds.), *Judgment Under Uncertainty: Heuristics and Biases*. Cambridge University Press.
- (1992). Advances in prospect theory: Cumulative representation of uncertainty. *Journal of Risk and Uncertainty*, 5(4), pp. 297-323.



---

COLABORACIONES

## **II. LA NUEVA GESTIÓN DE LA INFORMACIÓN BANCARIA**

## Resumen

En un contexto marcado por la creciente importancia estratégica de los datos, la industria financiera se enfrenta al importante desafío de conseguir salvaguardar sus ventajas comparativas sin comprometer, a su vez, la privacidad de los datos personales de sus clientes ni impedir que terceras partes puedan ejercer su legítimo derecho de acceso a los mismos. Se trata de un escenario complicado en el que, con independencia de las actuaciones que puedan emprender dichas entidades, resulta también necesario contemplar ciertas dosis de intervención pública. Entre otros aspectos, esta deberá orientarse no solo a garantizar que imperen unas reglas de juego equilibrado dentro del sector, sino que, además, se dirigirá a encontrar las fórmulas prácticas más convenientes para sacar el máximo provecho de la información digital disponible de cara al mejor desempeño de las funciones de regulación y supervisión que son propias de las autoridades.

*Palabras clave:* economía del dato, open banking, fintech, bigtech, supotech, privacidad.

## Abstract

In a context characterized by the increasing strategic importance of data, the financial industry faces the challenge of safeguarding their competitive advantages while not compromising the privacy of their clients' personal data, or restricting the lawful right of third parties to access such data. It is a complex framework that requires market-led initiatives to be accompanied by a certain degree of public intervention. Authorities should aim at ensuring a level-playing field and, moreover, at identifying the most convenient ways to extract the maximum benefit from the digital information that is available, in order to improve the implementation of the regulatory and supervisory practices that fall within their remit.

*Keywords:* economy data, open banking, fintech, bigtech, supotech, privacy.

*JEL classification:* G28, L11, O33.

# RETOS PARA LA GESTIÓN DE LA INFORMACIÓN FINANCIERA EN UNA ECONOMÍA DIGITALIZADA: LA PERSPECTIVA DE LAS AUTORIDADES FINANCIERAS

José Manuel MARQUÉS

Sergio GORJÓN

Ana FERNÁNDEZ

*Banco de España (\*)*

## I. INTRODUCCIÓN

**L**A captación, almacenamiento y tratamiento de información con la finalidad de mejorar el conocimiento del negocio y, por extensión, de facilitar la toma de decisiones que aporten valor es consustancial a la actividad financiera desde sus orígenes. Al jugar un papel clave en la intermediación del ahorro hacia la inversión, la banca ha disfrutado históricamente de un acceso, amplio y exclusivo, a un valioso conjunto de datos acerca del comportamiento de sus clientes; un activo cuya explotación ha resultado esencial en la identificación de nuevas oportunidades de negocio, la obtención de eficiencias o para potenciar la experiencia del usuario final.

El proceso de transformación digital en el que se halla inmerso nuestra sociedad ha permitido profundizar en esta dirección toda vez que el número de interacciones entre los agentes económicos se ha multiplicado, aumentando así el volumen de información disponible y posibilitando su procesamiento automatizado gracias al empleo de formatos, aplicaciones y equipos informáticos que la pueden manejar de manera directa. Al mismo tiempo, esta nueva rea-

lidad lleva aparejada múltiples e importantes desafíos cuya superación no solo no resulta sencilla, sino que es determinante a los efectos de poder asegurar la viabilidad comercial futura de la banca y el mejor aprovechamiento de las oportunidades que encierra.

En las siguientes secciones se exploran, en primer lugar, las características que como resultado de la digitalización creciente de la economía –y, en particular, de la mayor importancia del dato– definen y diferencian al actual entorno de competencia. A continuación se analizan las implicaciones que, para las entidades financieras, podría tener la concentración de datos y las condiciones de accesibilidad a los mismos. En tercer lugar se pone el foco en los factores que están limitando la existencia de un intercambio más homogéneo de la información a escala internacional, haciendo especial hincapié en la dimensión de la privacidad y en las iniciativas que buscan la convergencia hacia un estándar global. Finalmente, se cierra este artículo con una serie de reflexiones acerca de las adaptaciones que resultarían necesarias hacer, por parte de las autoridades de supervisión, con el fin de conseguir que la



información disponible permita el ejercicio óptimo de sus tareas.

## II. UN ENTORNO SOMETIDO A UN CAMBIO CONTINUO Y VELOZ

Uno de los factores que más ha distinguido al sector financiero en el pasado ha sido su carácter innovador, mostrándose siempre dispuesto a incorporar nuevas tecnologías con potencial para contribuir al mejor desempeño de su actividad. Sin embargo, en los últimos años, al igual que ocurre con otros sectores, esta industria está experimentando un proceso de transformación muy diferente al de épocas anteriores, en particular, en lo que respecta a la velocidad y la profundidad con la que se están produciendo los cambios (González-Páramo, 2017).

Este nuevo contexto se explica, principalmente, por la creciente digitalización que está experimentando la sociedad. A raíz de la generalización del uso de Internet en los hogares y del uso de los teléfonos móviles –en especial, los llamados *smartphones*–, este proceso ha avanzado a pasos agigantados en lo que se denomina el «fenómeno *fintech*». En otras palabras, la posibilidad de realizar operaciones financieras desde el móvil, en cualquier momento y desde cualquier lugar, de modo similar a lo que ocurre con otros servicios, ha supuesto también una modificación radical en la manera en que se ofrecen y demandan ahora los servicios financieros (Board of Governors of the Federal Reserve System, 2015). Por otra parte, la digitalización ha incrementado significativamente el grado de interconexión que existe entre distintos secto-

res y países, lo que facilita que los cambios puedan extenderse rápidamente tanto entre industrias como a nivel global.

Esta revolución digital, unida al desarrollo o aparición de multitud de nuevas tecnologías (p.ej., computación en la nube, registros distribuidos, inteligencia artificial, biometría...), tiene una serie de consecuencias que, en última instancia, están llevando a la redefinición del sector financiero en los siguientes términos (NTT Data, 2019):

- *Posibilidad de mejorar la provisión de servicios*: las nuevas tecnologías presentan, sin duda, un gran potencial para hacer más eficientes las tareas y los procesos necesarios para la prestación de servicios financieros. Los canales no presenciales permiten realizar, a distancia, una gran parte de la operativa que antes tenía lugar en las sucursales, el uso de la nube flexibiliza y reduce los costes de infraestructura, la inteligencia artificial ayuda a automatizar algunas tareas... Asimismo, las innovaciones tecnológicas permiten dar un mejor servicio a los usuarios mediante el desarrollo de nuevos canales o productos, mejorando la provisión de la oferta existente, ampliando el acceso a determinados servicios o personalizando la oferta para adaptarse a las necesidades de los clientes.
- *Entrada de nuevos actores*: la digitalización supone una disminución de las barreras que frenaban la entrada de nuevos oferentes en los mercados de servicios financieros. Por una parte, desaparece la necesidad de desarrollar una

gran red de sucursales ya que es posible llegar a un elevado número de clientes, tanto nacionales como de otros países, a través de canales no presenciales. Asimismo, la importancia de otras barreras, como la inversión en *software* o *hardware*, se diluye gracias a la emergencia de tecnologías innovadoras, como la computación en la nube que permite pagar en función del uso que se haga del servicio. Más aún, la relevancia que tienen cuestiones como la asimetría de información se aminoran gracias a las posibilidades que ofrecen las nuevas tecnologías para la obtención y el análisis de datos.

Surgen, así, nuevos actores que buscan dar respuesta a las demandas de los usuarios, especializándose en ciertos nichos y ofreciendo sus servicios de manera directa. O, alternatively, situándose como intermediarios entre el usuario final y la entidad financiera que los provee. Estos nuevos participantes se distinguen de las entidades tradicionales, principalmente, por su mayor flexibilidad, tanto para adoptar las nuevas tecnologías (1) como para adaptarse a las condiciones cambiantes del mercado.

- *Nuevas costumbres y expectativas*: la ubicuidad de Internet ha permitido que los consumidores se acostumbren a disponer de diversos servicios de manera inmediata, en ocasiones incluso gratuita, y con un mayor grado de personalización. Esta experiencia de usuario, que se está dando de manera progresiva en multitud de sectores (p. ej., comunicaciones, transporte, comercio minorista), genera

no solo nuevos modelos de negocio para las empresas, sino, también, nuevos hábitos en los consumidores que esperan poder disfrutar de algo similar en todos los ámbitos de sus vidas. Al mismo tiempo, nos encontramos con una nueva generación de clientes que no tienen ningún tipo de vinculación con las entidades financieras y solo buscan aquel servicio que mejor satisfaga sus necesidades. Ambos factores refuerzan la capacidad de los nuevos agentes de convertirse en alternativas reales a las entidades tradicionales.

La confluencia de estos tres elementos (nuevas tecnologías, actores emergentes y cambios en la demanda) dibuja un contexto muy distinto al observado en épocas pasadas: hasta ahora, el reto principal de las entidades financieras era adoptar las nuevas tecnologías que iban surgiendo, de manera progresiva, y sin que hubiera, en principio, una necesidad de cambio explícita por parte de los usuarios. Sin embargo, en la situación actual, las entidades financieras se enfrentan a un triple desafío (PwC & IE Business School, 2013). En primer lugar, tener que gestionar la complejidad y el coste asociado a la adopción de numerosas tecnologías que presentan una gran heterogeneidad y cuya compatibilidad con los sistemas tecnológicos heredados del pasado no resulta sencilla. Adicionalmente, poder dar respuesta a las necesidades de un nuevo tipo de usuario empoderado que espera un servicio similar al que ya obtiene en otros ámbitos y, finalmente, hacer frente a unos competidores mucho más dinámicos y con mayor capacidad para adaptarse a lo que busca la demanda.

Entre estos nuevos competidores se pueden distinguir dos grandes grupos (Padilla, 2019). Por una parte, las denominadas empresas *fintech*, que carecen, por lo general, del capital y la base de clientes de una gran entidad financiera, pero que, por el contrario, muestran gran flexibilidad para adaptarse, altos conocimientos de las nuevas tecnologías y una cultura centrada en el cliente. Por otro lado, las *bigtech*, grandes plataformas de Internet (p. ej., Facebook, Apple, Google) que no solo gozan de las ventajas que presentan las *fintech*, sino que disponen, además, de músculo financiero, sinergias entre actividades y un número muy significativo de clientes.

A todo lo anterior se añade otra cuestión diferencial del entorno actual, que es consecuencia también de la digitalización: la «datificación». La sociedad de la información ha traído de la mano la economía del dato, es decir, mucho (si no todo) de lo que hacemos en nuestro día a día deja un rastro en forma de datos. Gracias al aumento de la capacidad de almacenamiento y procesamiento computacional y a la mejora en los algoritmos, estos datos pueden ser aprovechados por las empresas para conocer mejor a los clientes (existentes y potenciales) y adelantarse a sus necesidades, ofrecer productos y servicios más personalizados, hacer más eficientes las campañas de *marketing*... En definitiva, los datos se han convertido en materia prima que está llevando a la aparición de nuevos modelos de negocio basados en la explotación de la información, tanto propia como recabada de terceros (Schüritz, Seebacher y Dorner, 2017).

Podría considerarse que la economía del dato sitúa a las entidades financieras en una posición privilegiada, ya que cuentan con gran cantidad de información sobre sus clientes. No obstante, una explotación eficiente de la información que almacenan las entidades requiere ajustes organizativos y técnicos que no siempre son sencillos de implementar (KPMG, 2014). Adicionalmente, algunos de los nuevos entrantes, en particular las *bigtech*, también tienen acceso a un volumen ingente de información sobre sus usuarios y, además, han nacido y crecido en torno a la explotación de esa información. En consecuencia, acumulan una gran experiencia y capacidad a la hora de aplicar las nuevas tecnologías de análisis de datos. En este contexto, para seguir siendo competitivas, las entidades financieras deben dedicar importantes esfuerzos a extraer y explotar adecuadamente toda la información de la que disponen.

Aunque hasta ahora el análisis se ha centrado en el impacto del fenómeno *fintech* en la industria, no cabe duda de que las autoridades también se enfrentan a una serie de retos (FSB, 2017). La entrada de nuevos actores provenientes de otros sectores y países, la rapidez con la que se producen los cambios, la aparición de multitud de nuevas tecnologías... son, sin duda, cuestiones que dificultan la tarea de asegurar la estabilidad del sistema financiero, la integridad del mercado o la protección de los consumidores, tanto como usuarios de servicios financieros como en lo que al uso de sus datos se refiere.

Al mismo tiempo, es importante encontrar un equilibrio

adecuado entre regulación e innovación, a fin de asegurar que los riesgos están gestionados de manera adecuada y, al tiempo, que no se coarta la innovación. Para ello, conviene seguir algunos principios básicos, como asegurar que actividades similares están sujetas a las mismas reglas (sin perjuicio de la conveniencia de incluir cierto grado de proporcionalidad para favorecer el despegue de pequeñas empresas) o que la regulación permanece tecnológicamente neutra y es lo suficientemente flexible como para poder dar cabida, fácilmente, a nuevos desarrollos (CEMLA, 2019).

### III. EL ALCANCE DEL ACCESO A LA INFORMACIÓN: ¿UN ENFOQUE SECTORIAL O UNIVERSAL?

En este entorno cambiante, marcado por la aparición de nuevos usos de la información financiera, uno de los fenómenos con mayor alcance a nivel internacional es lo que se ha venido a denominar «banca abierta» u *open banking*. Con este vocablo se designa a un amplio grupo de iniciativas encaminadas a permitir que terceras partes no bancarias puedan acceder a un conjunto de datos financieros que, hasta ahora, venían siendo privativos de las entidades de depósito; un objetivo deliberado tras que el que se esconden dos grandes finalidades. Por un lado, lograr que los usuarios puedan ejercer un mayor grado de control sobre el empleo que se da a la información que les afecta (privacidad). Por otro, favorecer el desarrollo de un mercado de productos y servicios más competitivo, de carácter innovador y con una mayor capacidad para

acomodar sus necesidades reales (competencia).

En Europa, este proceso se ha visto impulsado con la promulgación de la Segunda Directa de Servicios de Pago (PSD2) (2) mientras que, en otros países, los motores del cambio han sido de distinta índole. En algunos casos, se ha seguido una senda similar a la europea, con la adopción de normas específicas, orientadas a propiciar la más amplia circulación de datos sobre un extenso catálogo de servicios financieros. En otros, se ha optado por dar prioridad a la autorregulación si bien auspiciada, en mayor o menor medida, por las propias autoridades.

A pesar de sus diferencias prácticas, los enfoques anteriores coinciden en situar a la industria bancaria en su epicentro sin que, salvo contadas excepciones (3), se haya contemplado su extensión a otros sectores económicos. Esta circunstancia está generando un intenso debate acerca de sus potenciales implicaciones negativas, sobresaliendo en especial tres grandes cuestiones (4).

En primer lugar, preocupa que la parcialidad con la que se ha abordado el desafío de contribuir al mayor intercambio de datos favorezca un arbitraje regulatorio con otros agentes o sectores. Dado el carácter generalmente estrecho de estos regímenes solo un colectivo reducido de sujetos o una gama concreta de servicios se supedita a los mismos, quedando cualquier otra cuestión sujeta a la indefinición y, por extensión, a la unilateralidad. Este es, de hecho, el caso tanto de la PSD2 como del modelo de *open banking* del Reino Unido. En concreto, la PSD2 re-

gula los derechos de acceso a las cuentas de pago entre entidades acreditadas legalmente bajo su paraguas (5), pero evita pronunciarse en relación a otro tipo de servicios bancarios de relevancia.

De igual manera, si bien la propuesta británica se proyecta sobre un rango de actividades más amplio, en lo que respecta al universo de agentes afectados presenta una ambición limitada (solo algunos bancos). En contraposición a ambos regímenes, las grandes empresas de tecnología gozan, por lo general, de una extensa autonomía para decidir cuáles de los contenidos de sus bases de datos desean compartir con terceros así como las condiciones en que dicha circunstancia acabe teniendo lugar; es decir: el momento y los formatos (6). Por esta razón, se ofrece a los nuevos entrantes la oportunidad de beneficiarse de una serie de ventajas comparativas en forma de economías de aprendizaje que, sin embargo, les están vedadas a las entidades de depósito (CNMC, 2018; IOSCO, 2017). Las implicaciones de esta situación se amplifican a medida que no son solo las pequeñas empresas *fintech*, sino aquellas que acumulan volúmenes ingentes de datos quienes resultan favorecidas, dando así lugar a una clara asimetría cuya justificación no parece obvia (Mai, 2018; Fernández de Lis y Urbiola, 2018; Bamberger y Lobel, 2017).

Es, precisamente, este acceso preferencial por parte de las *bigtech* a la información que custodian los bancos lo que da pie a un segundo tipo de inquietudes no menos relevante: su impacto efectivo sobre el poder de mercado de las plataformas digitales en tanto que se conso-

lidan como silos de información opacos e impermeables. En su condición de empresas especializadas en la gestión y tratamiento de datos, estas grandes compañías tecnológicas basan gran parte de su éxito en su capacidad para acumular, asimilar y explotar comercialmente el conocimiento que se esconde detrás de inmensos volúmenes de información heterogénea. Un incremento en la cantidad, frecuencia y diversidad de la información a su disposición redundante, favorablemente, en su nivel de comprensión acerca de las necesidades y preferencias reales de los usuarios. Por tanto, estas empresas tienen la posibilidad de reformular su oferta de productos y servicios de una manera adaptativa, pudiendo adecuar la calidad, el precio o el alcance de la misma a lo que, en cada momento, demanden los clientes finales (Arner *et al.*, 2017; Bilotta y Romano, 2019).

En este sentido, la información financiera reviste un valor especial ya que este tipo de datos captura dimensiones relevantes de un mismo sujeto (p.ej., nivel de ingresos, capacidad de ahorro, situación patrimonial) amplificando, por tanto, la calidad del análisis y haciendo más efectiva la acción comercial (Wu, 2010). Esta circunstancia contribuye, además, a acentuar los efectos de red inherentes a los ecosistemas digitales (Stucke y Grunes, 2016; Fletcher, 2007) lo que origina un ciclo de retroalimentación positiva con una doble consecuencia. Por un lado, contribuye a consolidar el papel de las plataformas digitales como intermediarios centrales en un amplio abanico de interacciones desarrolladas por los agentes económicos. Por otro, refuerza su posición como oligopolios

de información toda vez que el crecimiento de la actividad dinamiza la corriente de datos que obtienen de forma natural. (BIS, 2019).

Por consiguiente, a las autoridades se les plantea el reto de no permanecer indiferentes antes las repercusiones de este proceso sobre los niveles de concentración (presencia de dinámicas *winner-takes-it-all*), neutralidad (existencia de conflictos de intereses [7]) y transparencia (discriminación de precios) que pueda presentar la industria en el medio plazo (Khan, 2016; Padilla y de la Mano, 2019) (8).

El tercer elemento importante se origina en torno a la naturaleza de los procesos de monetización del dato y en cómo estos inciden en la distribución equilibrada de este valor entre quienes lo generan y lo explotan (Arrieta Ibarra *et al.*, 2017). A diferencia de otros *inputs* productivos, el dato presenta una serie de propiedades económicas singulares. En primer lugar, constituye un bien no rival tal que puede ser consumido por un número ilimitado de agentes sin erosionar su utilidad. Además, dada su naturaleza inmaterial resulta fácilmente replicable de modo instantáneo. Por último, combinado con otras fuentes, el dato original ofrece la oportunidad de extraer nuevos conocimientos de forma dinámica (9).

Por todo ello, bajo las condiciones adecuadas (10), el intercambio de datos puede generar beneficios sociales superiores a los exclusivamente privados (Frischmann, 2012) mientras que su concentración en unos pocos jugadores, con potestad o facultades técnicas para excluir a otros de su acceso, encierra im-

portantes perjuicios potenciales: podría afectar al nivel de innovación, a las cifras de empleo y producción, limitaría el desarrollo de mercados complementarios, etc. (Crémer, De Montjoye y Schweitzer, 2019).

Adicionalmente, el bienestar de los consumidores puede verse afectado, al menos, de otras dos maneras. Por un lado, la posición de dominio de los agentes digitales hace que sea difícil para los consumidores poder extraer parte del excedente que genera el uso de los datos, haciéndose prácticamente imposible poder obtener algún tipo de compensación económica por ceder estos datos (generalmente la alternativa a no ceder el dato es no poder acceder a los servicios de la plataforma). Por otro lado, el diferencial de información acumulado por las plataformas digitales les habilita para desplegar una estrategia de discriminación de precios muy efectiva, impactando tanto sobre la demanda como, también, sobre la oferta (11) (Stucke, 2018). Esta política de extracción de los excedentes de ambas partes puede llegar a resultar muy efectiva toda vez que, al contrario de mercados más competitivos, las alternativas de los usuarios son aquí más limitadas y las asimetrías informativas mayores (Ezrachi y Stucke, 2016).

Ante los inconvenientes y falta de eficacia que lleva aparejado un modelo de compartición de datos de carácter sectorial, abundan las propuestas alternativas. Por ejemplo, en Norteamérica proliferan los defensores de las medidas de carácter estructural, que buscan separar la propiedad y gestión de la plataforma de otras líneas de negocio de carácter complementario (p.ej.,



servicios de búsqueda, publicidad *online*, asistentes virtuales). De este modo se podría poner fin al acceso preferencial a los datos que se canalizan a través de estas infraestructuras dando, en teoría, un trato más justo y equilibrado a todos los agentes económicos.

No obstante, desde un punto de vista social y operativo, la implementación de este tipo de actuaciones arroja importantes incertidumbres (Khan, 2019) como, por ejemplo, la dificultad para ponerlas en práctica sin repercutir sobre la productividad, la complejidad de encontrar un modelo de negocio viable tras la escisión (Cowen, 2019) o el riesgo de comprometer los niveles de bienestar público en comparación con la situación precedente al diluirse las sinergias existentes (Mayer-Schönberger y Ramge, 2018a).

Frente a estas propuestas más controvertidas, están tomando forma otras que parecen contar con un mayor respaldo internacional. Una de ellas es la aplicación de principios, reglas o códigos de conducta procompetitivos por parte de las plataformas que eviten el recurso a políticas de privacidad genéricas o ambiguas (OCDE, 2016) o que obliguen, a sus respectivos gestores, a primar el beneficio del consumidor frente al propio (Furman *et al*, 2019; Petrou, 2018).

Por otro lado, están ganando peso aquellas tesis que defienden la necesidad de ampliar el alcance de los regímenes de reparto de datos de modo que estos sean aplicables a todas las industrias bajo el principio de reciprocidad (Prüfer y Schottmüller, 2017). En términos prácticos la medida supone reforzar los

derechos de propiedad de los usuarios en relación a sus datos personales, para lo que se requiere un oportuno mandato legal que aporte la certidumbre necesaria (12).

La creación de este mercado de datos aspira a equilibrar los legítimos intereses de cada una de las partes afectadas, pero afronta desafíos prácticos considerables como los potenciales sesgos cognitivos de los agentes económicos para evaluar cuál es el flujo de datos más adecuado (Acquisti, John y Loewenstein, 2013), el escaso valor económico del dato individual frente al procesado (13) (Hofheinz y Osimo, 2017) o la falta de claridad respecto a la frontera entre el dato privado de carácter personal y el que no lo es. Otros problemas considerables son la dificultad de modular los derechos de acceso en atención a cómo de replicable y estratégico para la competencia sea un dato concreto, la emergencia de nuevas formas de proteccionismo digital (políticas de localización), la ausencia de estándares comunes que faciliten la interoperabilidad entre plataformas (Ilves y Osimo, 2018) o las incertidumbres acerca de cómo abordar la problemática específica de los datos privados de carácter no personal o los que son de titularidad pública.

#### IV. LA PRIVACIDAD: HACIA UNA FRAGMENTACIÓN DEL ACCESO A LA INFORMACIÓN

En un entorno globalizado como el actual, la posibilidad de compartir los datos entre distintas jurisdicciones constituye uno de los requisitos fundamentales para poder competir a gran escala. Este hecho resulta espe-

cialmente notable cuando se compara el alcance que pueden tener las propuestas financieras promovidas por las *bigtech* (14) con las de las entidades bancarias tradicionales, en las que la existencia de normas locales explica, en parte, la mayor fragmentación geográfica de sus iniciativas.

En este sentido, avanzar en una mayor coordinación internacional, en áreas como las mencionadas en la sección anterior, resulta fundamental para conseguir un marco global de gestión y acceso a los datos. Sin embargo, ciertas cuestiones presentan un mayor grado de complejidad a la hora de alcanzar un consenso o armonización como, por ejemplo, las relacionadas con la salvaguarda de la privacidad de las personas, con el grado de propiedad sobre los datos procesados o con la seguridad nacional.

En el caso particular de la seguridad nacional siempre han existido restricciones basadas en datos de naturaleza sensible o estratégica. Sin embargo, el uso de técnicas de inteligencia artificial implica que el rango de los mismos se amplíe dado que la existencia de relaciones subyacentes que no resultan evidentes aumenta la probabilidad de revelar aspectos delicados que, conforme a la legislación, han de estar protegidos. Por ello, algunos países esgrimen estas consideraciones para evitar que alguna o toda la información de carácter financiero pueda ser almacenada o usada fuera de su jurisdicción (IIF, 2019).

Con independencia de las dificultades que, para coordinarse mejor, entrañan los elementos idiosincráticos de cuestiones como la seguridad nacional, hay



veces que este tipo de argumentos ocultan motivaciones de carácter proteccionista; esto es, su objetivo es evitar que empresas extranjeras puedan acabar prestando sus servicios en un determinado país. De ahí que, en algunos tratados comerciales recientes, como el firmado en entre Estados Unidos, México y Canadá o el acuerdo transpacífico CTPP (15), se incluyan cláusulas que moderan el uso de este tipo de restricciones.

Otro razonamiento muy utilizado para condicionar la circulación de los datos es el relacionado con la resiliencia de las instituciones o infraestructuras ante eventos que conlleven un riesgo operativo como, por ejemplo, un ataque cibernético. Sin embargo, en estos casos, las restricciones no suelen materializarse en una limitación estricta a la transferencia internacional de la información. En su lugar, suelen implicar que se supedite dicho movimiento a que las condiciones de seguridad en el almacenamiento de los datos sean similares a las del país de origen. También pueden suponer la obligación de tener que mantener una copia de los datos en los servidores nacionales de modo que se garantice la restitución de la operativa en un tiempo prudencial.

Aunque este tipo de medidas no inhabilitan directamente el uso transfronterizo de la información pueden representar un encarecimiento del mismo impidiendo, de facto, que este pueda producirse con normalidad. Por este motivo, son frecuentes los intentos de coordinación entre los reguladores con el objeto de llegar a acuerdos que orienten estos requerimientos hacia la aplicación de criterios, exclusivamente, técnicos.

En relación con la propiedad intelectual, donde se observan mayores diferencias entre territorios es en lo que respecta a la calificación de un dato como procesado y, por tanto, cuándo este contiene un valor añadido que hay que proteger.

Por último, las cuestiones vinculadas con el ámbito de la privacidad son probablemente las que más atención despiertan, dado su alcance y su creciente importancia, sobre todo, tras episodios de uso indebido de datos como el de Cambridge Analytica o los numerosos sucesos de filtración de la información (16). Así, según una encuesta reciente de alcance global (véase CGI-Ipsos, 2019), casi el 80 por 100 de la población se muestra preocupada por el nivel de privacidad *online* existente. Además, esta preocupación parece ser creciente y, de hecho, más del 50 por 100 de los encuestados declara asignar más importancia a este hecho que en el año anterior.

En este contexto, no resulta sorprendente que en más de la mitad de los países que forman la muestra se hayan desarrollado legislaciones específicas, dirigidas a garantizar la protección de los datos personales (17). Sin embargo, las características culturales y sociales en torno a la privacidad hacen que existan diferencias notables entre jurisdicciones que, de nuevo, dificultan la circulación de la información y pueden ser fuente de arbitrajes regulatorios. Para solventar este problema varios organismos internacionales, como la ONU, el Consejo Europeo, la OCDE o la agrupación internacional de autoridades de protección de datos trabajan en establecer principios generales que con-

tribuyan a lograr cierto grado de consenso entre diferentes legislaciones (véase UNCTAD, 2016).

En cualquier caso, este tipo de iniciativas no dejan de ser, en la mayoría de los casos, voluntarias y de alto nivel, dejando así un margen excesivo que no evita que exista una importante fragmentación en cuanto al cuerpo de normas que rigen en materia de privacidad. Probablemente, los esfuerzos más prometedores de cara a fomentar un marco más homogéneo sean los correspondientes a las normas regionales de carácter general que, eventualmente, puedan acabar actuando como un referente para terceros países.

En este sentido, la propuesta más relevante e influyente hasta el momento es la del Reglamento General de Protección de Datos de la Unión Europea, de aplicación efectiva desde mayo de 2018, y que parece estar sirviendo de inspiración a iniciativas que se están gestando en otras geografías. Al mismo tiempo, aunque con menor grado de ambición que en el caso europeo, otras regiones también están tratando de mejorar la convergencia en materia de privacidad (18). En cualquier caso, a pesar de los beneficios de no tener un marco tan fragmentado para la privacidad, se está aún lejos de converger hacia un estándar global siendo, por tanto, necesario avanzar hacia una mayor coordinación internacional si se quiere definir un contexto adecuado para la gestión de la información en un mundo globalizado (19).

## V. LA ECONOMÍA DE LOS DATOS: RETOS Y OPORTUNIDADES PARA EL SUPERVISOR

Al margen de lo ya comentado acerca del marco que regule el acceso y tratamiento de la información, la explotación creciente de los datos digitales dentro de la industria financiera crea importantes desafíos para los supervisores. Estos se concretan no solo en términos de su capacidad para validar el correcto uso de las nuevas herramientas tecnológicas dentro del sector sino, también, en cuanto a cómo poder garantizar que, en todo momento, se mantiene un estricto cumplimiento de la normativa que resulta de aplicación. Al mismo tiempo, la nueva economía de los datos ofrece, a estas mismas autoridades, oportunidades singulares para incrementar la eficacia del ejercicio de las funciones regulatorias y supervisoras; un terreno apenas explorado hasta el momento, pero sobre el que se adivina un importante recorrido potencial y en torno al cual comienzan a acumularse las iniciativas (20).

En lo que respecta a los riesgos destacan, especialmente, los relacionados con las amenazas cibernéticas toda vez que es, precisamente, el sector financiero uno de los más afectados ya sea por su papel capital en la transferencia de valor dentro de la economía, por su dependencia aumentada de infraestructuras y soluciones tecnológicas de naturaleza crítica o por el simple hecho de acumular un significativo volumen de información susceptible de proporcionar sustanciales rendimientos monetarios (Kopp y Kaffenberger, 2017).

Contribuyen a acentuar la importancia de estos riesgos otras debilidades como, por ejemplo, las derivadas del mantenimiento e integración de sistemas y aplicaciones heredados que, en muchos casos, antedatan a la consolidación de Internet y de las redes abiertas (Friedman, 2016) y que, con frecuencia, son el resultado de solapar capas de soluciones tecnológicas no optimizadas globalmente. Así pues, junto a las evidentes consecuencias de estas amenazas en términos de disponibilidad e integridad de los servicios, son los compromisos de la confidencialidad y el riesgo de que dicha información se explote con un objetivo económico, los que reclaman una mayor atención por su incidencia patrimonial, reputacional y por sus posibles efectos en la confianza del sistema financiero en su conjunto (21).

Más allá de la vertiente cibernética, la correcta gestión y custodia de los datos personales constituye, en sí mismo, un desafío de considerables dimensiones para las entidades financieras; razón por la que se ha convertido en otra de las grandes inquietudes de las autoridades competentes. Esta circunstancia resulta tanto más relevante en Europa donde se ha desplegado un nuevo régimen de salvaguarda de la privacidad —el GDPR, General Data Protection Regulation— que intensifica las obligaciones que han de cumplir las organizaciones que manejen este tipo de datos.


En términos prácticos, la circunstancia anterior implica que las entidades tengan que adoptar un enfoque proactivo de cara a la identificación de los riesgos y a la formulación de unas medidas de control pro-

porcionadas soportando, por extensión, cargas y dificultades en absoluto triviales. En este sentido, los aspectos de mayor relevancia y complejidad son varios como, por ejemplo: la articulación de consentimientos específicos, libres e inequívocos que fundamenten el uso que vaya a dársele a los datos, la transparencia informativa, el despliegue de medidas que faciliten a los usuarios el ejercicio de sus derechos o la eficacia con la que se aborden los aspectos relacionados con el tratamiento de las transferencias internacionales de la información.

En cuanto al aprovechamiento del potencial inherente a los datos por parte del supervisor, cabe señalar que este no resulta inmediato puesto que el ejercicio de sus funciones está condicionado por las limitaciones prácticas que derivan de sus responsabilidades y dinámicas internas. Por consiguiente, la adopción de nuevas técnicas y fuentes de información en este ámbito se caracteriza por ser un proceso dilatado en el tiempo que viene precedido de numerosas salvaguardas y la necesidad de llevar a cabo análisis pormenorizados. No obstante, ya se están produciendo avances apreciables, tanto del lado de la automatización y digitalización de los procesos manuales como en lo que respecta a la ampliación de las herramientas que emplean las autoridades (véase gráfico 1); un hecho que apunta a la existencia de un interés y predisposición crecientes por su parte (Toronto Center, 2017).

Así las cosas, el objetivo de las principales iniciativas se sitúa en introducir mejoras en los niveles de accesibilidad y granularidad de la información que se emplea para la supervisión, in-

GRÁFICO 1  
MARCO CONCEPTUAL DE SUPTECH



Fuente: Banco Mundial (2018).

crementando así la frecuencia de las consultas a los repositorios que custodia cada una de las organizaciones reguladas. Esto conduce a una reducción de los tiempos de respuesta y repercute en una sensible minoración de los costes de cumplimiento que soportan los agentes privados. Por otro lado, la aceleración de los flujos de datos posibilita el despliegue de otros proyectos de apoyo a las tareas de supervisión o de regulación, bien anticipando problemas, deficiencias o conductas anómalas ante las que dar una respuesta urgente, bien facilitando la aplicación de la normativa de manera más consistente (22) (Butler y O'Brien, 2019).

Este tipo de movimientos presenta, no obstante, importantes incertidumbres como las que se derivan de las implicaciones operativas de los mismos o las que tienen su origen en las dificultades para asegurar, bien la bondad de las predicciones, bien la calidad de los datos que sirven de soporte. Otros desafíos importantes tienen que ver con la capacidad para salvaguardar adecuadamente la privacidad y, en su defecto, sus potenciales consecuencias reputacionales. Adicionalmente, actúan de freno otro tipo de cuestiones relacionadas con la adecuación y disponibilidad de los recursos informáticos, la capacitación del personal que deba ejercer estas tareas o el impacto

y las complejidades de cualquier cambio sobre la cultura corporativa (23) (Broeders y Prenio, 2018).

## VI. CONCLUSIONES

Al igual que ha venido ocurriendo con otras industrias, la digitalización creciente de la sociedad ha alcanzado también el ámbito de los servicios financieros. A consecuencia de este hecho, el sector está siendo objeto de un nuevo proceso de transformación que, a diferencia de etapas precedentes, se caracteriza ahora por la gran velocidad y profundidad con la que se están produciendo los cambios.



Una de sus facetas más destacadas es, sin duda, la relacionada con la distribución y explotación de un tipo de información que si bien, históricamente, custodiaban las entidades financieras en exclusiva, por diversas circunstancias, comienza a estar disponible para amplios colectivos de competidores potenciales. Este contexto plantea diversos desafíos para los actores ya asentados, incluyendo la necesidad de tener que acometer ajustes técnicos y organizativos de carácter complejo y costoso o la urgencia de encontrar fórmulas que aseguren su supervivencia.

Al mismo tiempo, esta circunstancia pone de manifiesto la existencia de riesgos importantes para el conjunto de la sociedad que, sin empañar los potenciales beneficios de un intercambio más amplio de la información, obligan a iniciar una reflexión seria sobre los posibles puntos de fricción que aconsejarían una actuación pública perentoria.

En este sentido, una posible hoja de ruta podría contemplar aspectos tales como el desarrollo de un marco normativo que ponga límites al atesoramiento de información de carácter estratégico o que fomente su mayor circulación intersectorial. También podría prestar atención a la necesidad de resolver los conflictos de interés con origen en la gestión de una plataforma y su uso para la comercialización directa de servicios propios. Del mismo modo, reclaman una solución efectiva otras cuestiones como las relacionadas con la privacidad, la seguridad nacional o la frontera entre lo que es un dato procesado y lo que no lo es.

Todas estas dimensiones entrañan, a su vez, importantes problemas de orden práctico de difícil resolución y obligan, además, a tener que adoptar un enfoque cooperativo de carácter tanto transversal como transnacional que se haga eco del alcance real del fenómeno subyacente. Si bien, por el momento, los avances en este terreno están siendo muy moderados cabe esperar cambios significativos en los próximos años.

Por último, las autoridades financieras están llamadas a acometer profundas adaptaciones internas que permitan tanto favorecer la extensa explotación de los datos digitales en la industria financiera como sacar un provecho directo de los mismos para la mejora del desempeño de sus funciones legales. Se trata de un proceso lento marcado por las cautelas que han de presidir cualquier cambio en el ámbito de los servicios públicos, pero donde ya se están produciendo avances notables en términos de frecuencia y granularidad de la información que se analiza o de facilitar la eliminación de ambigüedades en la interpretación de las normas.

Dada la relevancia de todas las cuestiones mencionadas y la rapidez con la que se podrían llegar a materializar los efectos negativos de las más destacadas, es tiempo ya de abordar la definición del paquete óptimo de medidas de política pública: un elenco de iniciativas coordinadas entre autoridades que, ante todo, deberá primar la existencia de un terreno de juego equilibrado dentro del ecosistema del dato y que, además, buscará minimizar las posibles consecuencias adversas que se han identificado.

## NOTAS

(\*) Este artículo es responsabilidad exclusiva de los autores y no refleja necesariamente la opinión del Banco de España o del Eurosistema. Los autores agradecen los comentarios y aportaciones de Carlos Conesa y Jara Quintanero.

(1) Ya que son nativas digitales y, por tanto, no cuentan con una infraestructura «tradicional» que deban adaptar.

(2) Directiva (UE) 2015/2366 del Parlamento Europeo y del Consejo de 25 de noviembre de 2015 sobre servicios de pago en el mercado interior y por la que se modifican las Directivas 2002/65/CE, 2009/110/CE y 2013/36/UE y el Reglamento (UE) n.º 1093/2010 y se deroga la Directiva 2007/64/CE.

(3) Australia es una de las pocas jurisdicciones que tiene previsto extender este régimen a la información disponible dentro de los sectores de la energía y de las telecomunicaciones. Sin embargo, por razones prácticas, por el momento solo la banca se ha visto afectada.

(4) Un cuarto elemento de importancia que, por razones de extensión, nos vemos obligados a obviar en el presente artículo es el relativo a los aspectos formales del intercambio de la información, es decir la forma en la que se puede o debe intercambiar la información. La falta de avances en cuanto a la existencia de estándares ampliamente aceptados se revela, con frecuencia, como un obstáculo destacado para el completo aprovechamiento del potencial que encierra el dato. De ahí, que algunas iniciativas de fuera de la Unión Europea aborden, de manera expresa, esta dimensión.

(5) Los denominados proveedores de servicios de pago conforme a la tipología recogida en el artículo 1 de dicha directiva.

(6) Esta situación se replica, con matices, en las diferentes jurisdicciones donde se han avanzado en los regímenes de banca abierta.

(7) Derivados de gestionar, simultáneamente, la infraestructura tecnológica que posibilita la comercialización de servicios financieros por parte de los bancos y ser, a su vez, oferente de una cartera competidora.

(8) Algunas de las cuestiones que están siendo objeto de un escrutinio particularmente intenso por parte de las autoridades son: la importancia de nuevas barreras de entrada en forma de restricciones al acceso o a la reutilización de la información (GRAEF, 2016); el incremento de los costes de cambio de proveedor por las ventajas informacionales adquiridas (EDLIN y HARRIS, 2013; BIACONTI y CIOCCA, 2019); la entidad de los subsidios cruzados entre actividades financieras y no financieras (FSB, 2019); el impacto del uso de estrategias «paquetización» de productos y

servicios (FROST *et al.*, 2018), así como la falta de imparcialidad en la prestación de servicios de asesoramiento (OCDE, 2016).

(9) Al combinar en tiempo real, por ejemplo, los registros de geolocalización de un teléfono móvil con datos relativos al historial crediticio y de pagos de un cliente bancario, sería posible anticipar cuando este se dispone a hacer una compra en un establecimiento comercial y poder, así, ofrecerle el producto financiero que más pueda convenirle en cada caso.

(10) Es decir, medidas que contribuyan a, por ejemplo, preservar el régimen de privacidad de los datos personales, evitar comprometer los incentivos comerciales a su captación y tratamiento, impedir la revelación de secretos industriales, prevenir la difusión de información relativa a precios o costes que pudiera favorecer el establecimiento de acuerdos de colusión, etc.

(11) En términos de demanda, la plataforma puede ajustar sus precios hasta aproximarse al umbral de tolerancia de cada usuario. Por el lado de la oferta, puede comprimir sus márgenes basándose en las limitaciones de estos para poder determinar, con claridad, dónde se sitúan las preferencias de los consumidores finales. Por el lado de la demanda, puede empujar el precio hasta el límite de cada uno de los agentes en función de sus deseos y de las limitaciones que impone su respectiva capacidad económica.

(12) Las complejidades y costes asociados a una medida de estas características recomiendan la adopción de un enfoque proporcional que module la intensidad de las exigencias en función de lo representativa que resulte cada empresa en el mercado de datos. El *progressive data sharing* permite ajustar el volumen de información a compartir e, incluso, excluir a ciertos operadores cuando su tamaño así lo justifique. Otros aspectos recogidos en estas propuestas son, por ejemplo, la necesidad de contar con una contraprestación monetaria adecuada o la aplicación de controles que eviten la presencia de sesgos en los datos que se ponen a disposición de los demás. Véase, MAYER-SCHÖNBERGER y RAMGE (2018b) o BIANCOTTI y CIOCCA (2019).

(13) El procesamiento supone la ejecución de una serie de operaciones sobre el dato original que contribuyen a su enriquecimiento (depuración de errores, combinación con otras fuentes, etc.).

(14) Un buen ejemplo de esta ambición lo plantea la iniciativa Libra, promovida por Facebook, y que aspira a servir como medio de intercambio en un amplio número de países.

(15) *Comprehensive and Progressive Agreement for Trans-Pacific Partnership* que incluye a Australia, Canadá, Japón, México, Australia, Nueva Zelanda, Singapur y Vietnam.

(16) Uno de los casos más recientes es el de *Capital One Financial Corporation*, el quinto mayor emisor de tarjetas de crédito de Estados Unidos. A finales de julio de 2019, dicha entidad denunció haber sido objeto de uno de los robos de registros confidenciales más importantes de la historia del país y cuyo alcance potencial superó los 100 millones de personas.

(17) Una lista de los países con estas legislaciones pueden encontrarse en: [https://unctad.org/en/Pages/DTL/STI\\_and ICTs/ICT4D-Legislation/eCom-Data-Protection-Laws.aspx](https://unctad.org/en/Pages/DTL/STI_and ICTs/ICT4D-Legislation/eCom-Data-Protection-Laws.aspx)

(18) Por ejemplo, en Asia a través del Foro de Cooperación Económica Asia-Pacífico o en Latinoamérica con la Red de Protección de Datos Iberoamericana.

(19) En este sentido, resulta interesante subrayar la existencia de un número creciente de iniciativas regionales para fomentar la circulación de información. Esta circunstancia podría, potencialmente, facilitar la adopción de pasos para lograr una mayor convergencia internacional. A modo de ejemplo, desde la UE se han puesto en marcha un conjunto de actuaciones dirigidas a la consolidación de un Espacio Común de Datos que contribuya a dinamizar el empleo, impulsar el crecimiento económico y la innovación.

(20) Esta área se conoce, genéricamente, bajo el nombre de *SupTech*.

(21) Los resultados de un reciente estudio realizado por el Ponemon Institute revelan que una de las principales consecuencias de un compromiso de la privacidad de los datos es, precisamente, la pérdida de negocio potencial a consecuencia de la desconfianza generalizada que se instala en los usuarios.

(22) Nos referimos, en concreto, a los esfuerzos por avanzar en la codificación de las disposiciones legales (*machine-readable regulation*) como mecanismo para reducir tanto el margen que pudiera existir para su interpretación subjetiva como los plazos para su implementación.

(23) Lo que incluye, entre otras cuestiones, lograr un apoyo decidido de los órganos de gobierno de las instituciones, asegurar la financiación necesaria, orientar las organizaciones hacia una cultura del dato que implique la desaparición de silos a favor de una gestión integrada de la información, etc.

## BIBLIOGRAFÍA

ACQUISTI, A., JOHN, L. K. y LOEWENSTEIN, G. (2013). What Is Privacy Worth?, *The Journal of Legal Studies*, 42(2), pp. 249-274.

ARNER, D. W., ZETZSCHE, D. A., BUCKLEY, R. P. y BARBERIS, J. N. (2017). Fintech and Regtech: Enabling Innovation While Preserving Financial Stability. *Georgetown Journal of International Affairs*, 18(3), pp. 47-58.

ARRIETA IBARRA, I., GOFF, L., JIMÉNEZ HERNÁNDEZ, D., LANIER, J. y WEYL, E. G. (2017). Should We Treat Data as Labor? Moving Beyond 'Free'. *AEA Papers and Proceedings*, 108, pp. 38-42.

BAMBERGER, K. A. y LOBEL, O. (2017). Platform Market Power. *Berkeley Technology Law Journal*, 32(3), pp. 1051-1092.

BANCO MUNDIAL (2018). From Spreadsheets to Suptech: Technology Solutions for Market Conduct Supervision. *Discussion Note*.

BANK FOR INTERNATIONAL SETTLEMENTS (2019). *Annual Economic Report*. Basilea.

BIANCOTTI, C. y CIOCCA, P. (2019). Opening Internet Monopolies to Competition with Data Sharing Mandates. *Policy Brief*, 19-3. Peterson Institute for International Economics.

BILOTTA, N. y ROMANO, S. (2019). Tech Giants in Banking: The Implications of a New Market Power. *Istituto Affari Internazionali Papers*, 19/13.

BOARD OF GOVERNORS OF THE FEDERAL RESERVE SYSTEM (2015). *Consumers and Mobile Financial Services 2015*. Federal Reserve Board Publications.

BROEDERS, D. y PRENIO, J. (2018). Innovative technology in financial supervision (suptech) – the experience of early users. *FSI Insights on policy implementation*, 9. Banco Internacional de Pagos.

BUTLER, T. y O'BRIEN, L. (2019). *Understanding RegTech for Digital Regulatory Compliance*. Disrupting Finance, Palgrave Studies in Digital Business & Enabling Technologies, Palgrave Pivot, Cham,

CENTRO DE ESTUDIOS MONETARIOS LATINOAMERICANOS (2019). *Key Aspects around Financial Technologies and Regulation Policy report*.



- CIGI-IPSOS (2019). *CIGI-Ipsos Global Survey on Internet Security and Trust*. [www.cigionline.org/internet-survey-2019](http://www.cigionline.org/internet-survey-2019)
- COMISIÓN NACIONAL DE LOS MERCADOS Y LA COMPETENCIA (2018). *Estudio sobre el impacto en la competencia de las nuevas tecnologías en el sector financiero (fintech)*. E/CNMC/001/18.
- COWEN, T. (2019). *Big Business: A Love Letter to an American Anti-Hero*. St. Martin's Press.
- CRÉMER, J., DE MONTJOYE, I. A. y SCHWEITZER, H. (2019). *Competition Policy for the digital era: Final Report*. Publications Office of the European Union.
- EDLIN, A. S. y HARRIS, R. G. (2013). The Role of Switching Costs in Antitrust Analysis: A Comparison of Microsoft and Google. *Yale Journal of Law and Technology*, 15(2), Article 4.
- EZRACHI, A. y STUCKE, M. E. (2016). Virtual Competition. *Journal of European Competition Law & Practice*, 7(9), pp. 585-586.
- FERNÁNDEZ DE LIS, S. y URBIOLA ORTÚN, P. (2018). Transformación digital y competencia en el sector financiero. *Revista de Economía ICE*, 905.
- FINANCIAL STABILITY BOARD (2017). *Financial Stability Implications from FinTech: Supervisory and Regulatory Issues that Merit Authorities' Attention*.
- (2019). *FinTech and market structure in financial services: Market developments and potential financial stability implications*.
- FLETCHER, A. (2007). Predatory Pricing in Two-Sided Markets: A Brief Comment. *Competition Policy International*, 3(1), pp. 221-224.
- FRIEDMAN, S. (2016). *Taking cyber risk management to the next level—Lessons learned from the front lines at financial institutions*. Deloitte Insight.
- FRISCHMANN, B. M. (2012). *Infrastructure: the social value of shared resources*. Oxford University Press.
- FROST, J., GAMBACORTA, L., HUANG, Y., HYUN, H. S. y ZBINDEN, P. (2019). BigTech and the changing structure of financial intermediation. *BIS Working Papers*, 779.
- FURMAN, J., COYLE, D., FLETCHER, A., MCAULEY, D. y MARDSEN, P. (2019). *Unlocking digital competition: Report of the Digital Competition Expert Panel*. Her Majesty Treasury.
- GRAEF, I. (2016). *Competition Law, Data Protection and Online Platforms: Data as Essential Facility*. International Competition Series, Kluwer Law International B.V.
- GÓNZALEZ-PÁRAMO, J. M. (2017). Financial innovation in the digital age: challenges for regulation and supervision. *Revista de Estabilidad Financiera*, 32(5), pp. 9-37.
- HOFHEINZ, P. y OSIMO, D. (2017). *Making Europe a Data Economy: A New Framework for Free Movement of Data in the Digital Age*. The Lisbon Council.
- IIF (2019). *Data Flows across borders: Overcoming data localization restrictions*. Marzo
- ILVES, L. K. y OSIMO, D. (2018). *Policy Brief: A Roadmap for a Fair Data Economy*. The Lisbon Council & Sitra.
- IOSCO (2017). *Research Report on Financial Technologies (FinTech)*.
- KHAN, L. (2016). Amazon's Antitrust Paradox. *Yale Law Journal*, 126(3), pp. 710-805.
- (2019). The Separation of Platforms and Commerce. *Columbia Law Review*, 119(4), pp. 973-1093.
- KOPP, E., L. y KAFFENBERGER, C. W. (2017). Cyber Risk, Market Failures, and Financial Stability. *IMF Working Paper*, n.º 17/185.
- KPMG (2014). *Managing the data challenge in banking: Why is it so hard?* Suiza.
- MAI, H. (2018). *PDS2, open banking and the value of personal data*, EU Monitor: Digital economy and structural change, Deutsche Bank Research.
- MAYER-SCHÖNBERGER, V. y RAMGE, T. (2018a). *Reinventing Capitalism in the Age of Big Data*. Basic Books.
- (2018b). A Big Choice for BigTech: Share Data or Suffer the Consequences. *Foreign Affairs*, 97(5).
- NTT DATA CORPORATION (2019). *Digital to the Core: Transforming Financial Services and Insurance in the New World of Digital Business Platforms and Ecosystems*, NTT Research Paper, Financial Services & Insurance.
- OCDE (2016). *Big Data: Bringing Competition Policy To The Digital Era*, Directorate for Financial and Enterprise Affairs Competition Committee, DAF/COMP(2016)14.
- PADILLA, J. y DE LA MANO, M. (2019). BigTech Banking. *Journal of Competition Law & Economics*, 14(4).
- PETROU, K. (2018). *The Crisis Next Time: The Risk of New-Age Fintech and Last-Crisis Financial Regulation*. Federal Financial Analytics.
- PONEMON INSTITUTE (2017). *2017 Cost of Data Breach Study*, Junio.
- PRÜFER, J. y SCHOTTMÜELLER, C. (2017). Competing with big data. *TILEC Discussion Paper*, n.º 2017-006.
- PWC y IE BUSINESS SCHOOL (2013). *La banca, en la encrucijada. El futuro del sector financiero español en un mundo global*.
- SCHÜRITZ, R., SEEBACHER, S. y DORNER, R. (2017). Capturing Value from Data: Revenue Models for Data-Driven Services. *Proceedings of the 50th Hawaii International Conference on System Sciences*. IEEE, Hilton Waikoloa Village, Hawaii.
- STUCKE, M. E. (2018). Should We Be Concerned About Data-Opolies? *Georgetown Law Technology Review*, 275.
- STUCKE, M. E. y GRUNES, A. P. (2016). *Big Data and Competition Policy*. Oxford University Press.
- TORONTO CENTRE (2017). *FinTech, RegTech and SupTech: What They Mean for Financial Supervision*. Toronto Centre.
- UNCTAD (2016). *Data protection regulations and international data flows: Implications for trade and development*. United Nations.
- WU, T. (2010). *The master switch: The rise and fall of information empires*. Nueva York: Alfred A. Knopf.

# LAS NUEVAS OPORTUNIDADES DEL *BIG DATA* PARA LAS INSTITUCIONES FINANCIERAS

Pedro GALEANO

Daniel PEÑA

Universidad Carlos III de Madrid

## Resumen

Este trabajo describe el actual entorno de información masiva, el llamado *Big Data*, en el que se mueven hoy las entidades financieras y analiza las nuevas oportunidades para bancos, cajas de ahorros y otras instituciones financieras de utilizar los nuevos datos disponibles sobre sus clientes, presentes y potenciales, para mejorar sus estrategias comerciales. Se describen las nuevas formas de información disponible, que incluyen no solo las tablas de datos numéricos tradicionales, sino imágenes, textos de la web y datos temporales y espaciales, a veces en forma de funciones. Estos nuevos datos pueden revelar patrones de comportamiento y de relaciones entre variables que permitan segmentar mejor la clientela y construir modelos con mayor capacidad predictiva que los actuales. Se revisan brevemente algunas de las nuevas herramientas desarrolladas en los últimos años bajo los nombres de «aprendizaje estadístico» (*statistical learning*), «inteligencia artificial» y «aprendizaje automático» (*machine learning*) y su potencial en distintos problemas, como predicción personalizada, análisis de redes de clientes, prevención del fraude o detección de la lealtad de los clientes, entre otros. Por último, se presenta un ejemplo de cómo la construcción de redes de clientes y su análisis puede mejorar las políticas comerciales en un gran banco internacional.

**Palabras clave:** aprendizaje automático, aprendizaje estadístico, *Big Data*, redes de clientes.

## Abstract

This paper describes the current mass information environment, the so-called Big Data, in which financial institutions move today and analyses the new opportunities that this situation generates for banks and financial institutions to use the new data available on their present and potential clients to improve their marketing strategies. The new forms of available information are described, which include not only traditional numerical data tables, but images, web texts and temporal and spatial data, sometimes in the form of functions. These new data can reveal patterns of behaviour and relationships between variables that allow better customer segmentation and build models with greater predictive capacity than current ones. Some of the new tools developed in recent years under the names of statistical learning, artificial intelligence, and machine learning are briefly reviewed and their potential in different problems, such as personalized prediction, customer network analysis, fraud prevention or customer loyalty detection. Finally, an example is presented of how the construction of customer networks and their analysis can improve trade policies in a large international bank.

**Key words:** machine learning, statistical learning, Big Data, customer networks.

**JEL classification:** C10, C55.

## I. *BIG DATA*: LOS NUEVOS DATOS MASIVOS

**P**OR primera vez en la historia de la humanidad existen, en la mayoría de los países, datos abundantes, accesibles y con bajo coste, sobre muchos aspectos del comportamiento de los ciudadanos. Muchos de estos datos se han generado automáticamente, por el uso de dispositivos digitales conectados a Internet, especialmente teléfonos móviles, o por sensores y escáneres que los recogen. Por ejemplo, los escáneres de un supermercado guardan la información detallada de los productos adquiridos por clientes identificados con tarjetas de fidelidad o las transacciones electrónicas con tarjetas bancarias informan no solo sobre el importe de la venta, sino del tipo de comercio, día, hora y lugar, y lo mismo ocurre con muchos de los sistemas de compras *online*. Además, el desarrollo de la tecnología permite almacenar, con escaso

coste, estas grandes masas de datos, analizarlos de forma rápida y utilizarlos para obtener valor comercial. Por ejemplo, personalizando los anuncios que se muestran en el teléfono móvil en función del perfil del usuario.

Una de las empresas paradigmáticas en la recogida de información de sus clientes es Google: ocho de sus servicios cuentan con más de 1.000 millones de usuarios, una proporción importante de la población mundial actual, del orden de 7.000 millones de personas, de los cuales se estima que la mitad utilizan Internet. Alphabet, la matriz de Google, dispone de varios gigas de información de cada uno de sus usuarios que, desde hace poco tiempo, pueden además descargarla: incluye las páginas web consultadas, los vídeos de YouTube vistos, las reservas de hoteles y aviones realizadas y, si no tiene desactivada la

geolocalización, las coordenadas de su posición en cada momento, sus contactos y su correo. Además de Google, empresa pionera en este campo, las redes sociales, como Facebook, Twitter o Instagram, almacenan masas de información sobre sus usuarios incluyendo sus contactos, sus fotos y vídeos. Muchas otras aplicaciones recogen a través del uso del teléfono móvil información sobre nuestro comportamiento para formar bancos de datos de valor comercial. El nombre de *Big Data* se refiere principalmente a estas nuevas masas de datos recogidos de forma automática que están ya cambiando el mundo en que vivimos y que engloban no solo los datos personales de millones de personas, sino los datos recogidos por sensores instalados para seguir el comportamiento de animales, el crecimiento de los cultivos, el funcionamiento de máquinas y procesos o la evolución de fenómenos meteorológicos o climáticos.

Para poner en perspectiva que representan varios *gigabytes* (GB) de información de millones de personas, resumiremos brevemente la evolución de la capacidad para almacenar datos digitales y procesarlos. La unidad mínima de almacenamiento digital es un *bit* (b), que representa dos posibles valores para una variable (0,1). Por ejemplo, una bombilla puede estar apagada (0) o encendida (1). Uniendo 8 bits se obtiene un *byte* (B), con el que podemos formar 256, ( $2^8$ ) caracteres (letras, números o símbolos). Con 4 bytes podemos representar un número de cuatro cifras o una palabra con cuatro letras, y una página de papel DIN A4 escrita a máquina con unas 500 palabras y un tamaño medio de cuatro letras por palabra requiere alrededor de 2.000 B o 2 KB ( $1 \text{ KB} = 1.000 \text{ bytes}$ ). Un libro impreso de 350 páginas ocupa unos 400  $\text{KB} = 400 \times 10^3 \text{ bytes}$ . Los primeros ordenadores personales (PC) tenían discos *floppy* capaces de almacenar un libro (360 KB). Los discos duros fijos iniciales de los PC tenían una capacidad de 20 *megabytes* ( $\text{MB} = 1.000 \text{ KB} = 10^6 \text{ bytes}$ ), lo que permitía almacenar unas decenas de libros, y pasaron, a comienzos de este siglo, a una capacidad de varios *gigabytes* ( $\text{GB} = 1.000 \text{ MB} = 10^9 \text{ bytes}$ ), suficientes para almacenar fotos (entre 50 KB y 2 MB), música (una sinfonía ocupa unos 80 MB), o películas (entre 5 y 1,5 GB). Hoy, un PC puede almacenar varios *terabytes* ( $\text{TB} = 1.000 \text{ GB} = 10^{12} \text{ bytes}$ ), es decir, cientos de películas, miles de canciones y fotos y cientos de miles de libros. Como referencia, la colección impresa de la Biblioteca del Congreso de los EE.UU. ocupa actualmente del orden de 15 *terabytes* y, seguramente el año

que viene, podremos llevarla en el bolsillo en un disco duro transportable. Los servidores actuales tienen capacidad de *petabytes* ( $\text{PB} = 1.000 \text{ TB} = 10^{15} \text{ bytes}$ ) y pronto lo tendrán de *exabytes* ( $\text{EB} = 1.000 \text{ PB} = 10^{18} \text{ bytes}$ ). Por ejemplo, una de las bases de datos científicas mayores del mundo, el *World Data Centre for Climate (WDCC)*, almacena unos 400 *terabytes* de información. La base de datos de Google de varios GB de millones de usuarios supone varios *petabytes*. La cantidad diaria de datos generados en la actualidad de forma automática se estima de varios *exabytes*.

El rápido crecimiento de la capacidad de almacenar información ha venido de la mano de la facilidad de acceso gracias a lo que se denomina «la nube» y que consiste en redes de ordenadores conectados a Internet que son accesibles a través de la web. Por ejemplo, los servicios Dropbox, iCloud o Google Drive permiten a los usuarios acceder a sus archivos desde cualquier dispositivo con conexión a Internet.

Estos nuevos datos, el *Big Data*, y su facilidad de acceso y procesado, están ya cambiando todas las parcelas de nuestra actividad: cómo cuidamos nuestra salud, utilizamos nuestro ocio y nos relacionamos (Mayer-Schonberger y Cukier, 2013). También cómo aprendemos, véase Einav y Levin (2014) para su influencia en el análisis económico. Los datos masivos están teniendo una influencia decisiva en la posición relativa de las empresas en cada sector y cambiando las grandes empresas en el mundo. Por ejemplo, a finales del siglo XX las diez mayores compañías mundiales por valor en bolsa pertenecían principalmente a los sectores del petróleo y la fabricación de coches, mientras que en 2019 siete de las diez mayores empresas del mundo están basadas en la combinación de tecnología, *software* y *Big Data* y las cuatro primeras (Microsoft, Apple, Amazon y Alphabet/Google) han sido decisivas en impulsar la revolución de los datos masivos.

Es previsible que la tendencia a crear nuevos datos masivos y a procesarlos con rapidez siga acelerándose en el futuro. En particular, la posible aparición del ordenador cuántico incrementaría de forma gigantesca nuestra capacidad de procesado y crearía nuevas oportunidades en todos los campos, produciendo cambios fundamentales en el mundo tal como lo vemos hoy.

## II. LA INFORMACIÓN EN LOS NUEVOS DATOS

### 1. Codificación para su análisis

Los nuevos datos ofrecen retos cuantitativos y cualitativos. Además, la cantidad de información útil que contienen es muy variable. Unas pocas medidas precisas realizadas en condiciones controladas en un experimento ocupan pocos bytes y pueden tener un alto valor para la predicción de la variable medida. Una foto de alta resolución del experimento, que requiere varios megabytes, puede no contener ninguna información útil para la predicción. En general, la densidad de información de los nuevos datos recogidos automáticamente es mucho menor que la de los obtenidos con un objetivo, pero, a cambio, nos proporcionan información muy desagregada de nuevas situaciones que nunca habíamos imaginado ser capaces de analizar. Por ejemplo, los datos de geolocalización indican la posición de cada persona en el espacio en cada instante, permitiendo fácilmente conocer donde duerme, si trabaja o no y dónde, si acude regularmente a un hospital o centro médico y con qué frecuencia, si frecuenta restaurantes orientales o conciertos de música electrónica, etc. Se ha comprobado que esta información es más precisa que la que cada persona recuerda de sus hábitos y movimientos, que esta filtrada por nuestra memoria selectiva: numerosos experimentos han demostrado que la mayoría de las personas se sorprenden al comprobar la regularidad de sus hábitos y la predictibilidad de sus acciones. (Kahneman, 2012).

Hasta este siglo los datos se recogían con un objetivo específico, generalmente conocer una situación descrita por un conjunto de variables (el funcionamiento de un hospital, de un aeropuerto o la economía de un país) y utilizar este conocimiento para prever valores futuros de algunas de esas variables en función de las restantes (la demora en un tratamiento, la probabilidad de retraso o el crecimiento del PIB). Muchas instituciones financieras, como los bancos comerciales, disponen de conjuntos de variables asociadas a cada cliente, como edad, profesión, saldo en cuenta a final de mes, ingresos recibidos, recibos pagados, etc., que pueden utilizar para construir un modelo explicativo que prevea en función de ellas una variable respuesta de interés, como la probabilidad de mora, de un crecimiento en sus ingresos futuros, etc. Estos datos se agrupaban habitualmente en tablas de filas y columnas que recogen valores numéricos y caracteres de los clientes. Su procesamiento consiste en convertir

las variables cualitativas, descritas por caracteres, en variable numéricas: por ejemplo, la característica sexo se convertía en una variable con dos valores, 1 mujer y 0 hombre. De esta forma, todas las variables se agrupan en una matriz numérica donde, por ejemplo, en filas aparecen las personas y en columnas las variables.

Ahora, además de los datos tradicionales, el banco puede tener acceso a otra información sobre sus clientes, como su actividad en redes sociales, incluyendo fotos, audios y vídeos, o sus datos en otros ficheros de uso público. Estos nuevos datos son un conjunto de información no estructurada que hay que organizar para convertirla en posibles variables explicativas numéricas, que puedan ser objeto de análisis. En general, en lugar de disponer para cada persona de un conjunto pequeño de variables, tendremos un conjunto amplio de matrices numéricas relacionadas entre sí. Por ejemplo, una imagen digital es una matriz formada por celdas, que llamamos píxeles, donde en cada una de ellas se ha definido un color. Una imagen en blanco y negro contiene en cada celda un solo número, la intensidad de gris. Una en color con el sistema RGB (*red, green, blue*) contiene tres números, las intensidades de rojo, verde y azul, que al combinarse generan todas las tonalidades de colores. Por tanto, la representación de una imagen en color requiere tres matrices, cada una con tantas celdas como píxeles tenga la imagen, que se combinan con la intensidad definida en cada matriz para formar el color del píxel correspondiente. De la misma forma, un audio se codifica con números que representan intensidad de distintas frecuencias de la voz humana a lo largo del tiempo. Con los nuevos datos a cada persona podemos asignarle un gran número de esas matrices.

Cómo resumir toda esta gigantesca información en un número manejable de variables que puedan analizarse es un problema complejo. En la práctica, se seleccionan de todos los datos disponibles los rasgos o variables que parecen *a priori* prometedores, creando un número de variables explicativas que suele ser muy amplio. Además, es habitual encontrar heterogeneidad: la relación entre las variables puede no ser la misma para personas con distintos hábitos que se manifiestan en sus pautas de consumo o en su actividad en las redes sociales y debemos construir modelos distintos para clientes diferentes. Es frecuente con datos muy desagregados, como los que estamos hablando, que la relación entre dos variables puede depender de una



tercera creando interacción, o una relación no lineal entre ellas, lo que hace más complejo su análisis.

Una diferencia fundamental entre los datos clásicos y los nuevos es que, en el pasado, la distinción entre elementos a estudiar y variables era muy clara, con muchos elementos observados y unas pocas variables a estudiar en cada uno de ellos. Con los datos masivos, esa distinción se hace más ambigua e incluso, se pierde. Por ejemplo, al analizar el genoma humano nos encontramos con miles de datos de genes de pocas personas, cuando, hasta entonces, lo habitual eran unas pocas variables de muchas personas. Tiene ventajas ver el problema como una población de muchos genes, que son los elementos de la población, que observamos en ciertas variables, que son las personas, dando la vuelta al análisis convencional. En el campo financiero suponemos que analizamos muchas variables económicas y financieras de un pequeño núcleo de clientes clave en un banco. Podemos considerar que los elementos son las muchas medidas que caracterizan su comportamiento y las variables las personas estudiadas. Los nuevos tipos de datos pueden, según los objetivos del análisis, clasificarse en distintas dimensiones y seleccionar la más eficaz para analizarlos.

## 2. Extraer la información del *Big Data* con estadística

El objetivo de analizar los datos es convertirlos en información. Esta información aumenta nuestro conocimiento de las variables relevantes y las relaciones entre ellas y puede utilizarse para tres objetivos fundamentales. El primero, que suele denominarse *análisis descriptivo*, consiste en resumir las variables en unos pocos indicadores que nos sirvan para entender su estructura y las relaciones que hay entre ellas. Con este objetivo se intenta obtener conocimiento de las variables y datos presentes. El segundo objetivo se denomina *aprendizaje no supervisado* o métodos de clúster, y consiste en encontrar grupos de elementos o variables que tienen un comportamiento similar en los datos disponibles. Se denomina no supervisado porque se aplica a situaciones donde queremos dividir los datos en grupos homogéneos, pero no tenemos *a priori* ninguna información sobre el número de los grupos presentes ni de las variables que son importantes para definir estos grupos. El tercer objetivo, *aprendizaje supervisado*, consiste en prever una variable, o un conjunto de variables relacionadas entre sí, en

función de otras muchas. Además, estos objetivos pueden ser estáticos, si los datos se refieren a un instante fijo de tiempo, o dinámicos, si disponemos de la evolución de las variables en el tiempo y/o en el espacio.

Estos tres objetivos se han estudiado tradicionalmente por la estadística, poniendo el énfasis en la comprensión de las relaciones a través de la modelización de relaciones causales. La aparición de nuevos datos no convencionales (imágenes, señales, funciones, etc.) para resolver nuevos problemas (reconocimiento de lenguaje, visión artificial, etc), donde es muy complejo entender la relación entre las variables y los nexos casuales ha generado un conjunto de métodos adicionales de *inteligencia artificial* y *aprendizaje automático* encaminados a explotar las correlaciones encontradas entre las variables para mejorar la predicción.

La estadística (*Statistics*, *ST*) ha sido el motor del avance en el conocimiento empírico en el siglo XX. Su origen es relativamente muy reciente, ya que aunque el cálculo de probabilidades aparece como parte de la matemática en el siglo XVII, el análisis de datos para inferir propiedades de una población se hace posible cuando R. A. Fisher crea, en el primer tercio del siglo pasado, las bases de la inferencia estadística. Debemos también a Fisher los principios y métodos del diseño de experimentos para aprender y contrastar hipótesis en situaciones donde, fijando las variables de control, la respuesta observada tiene variabilidad. Durante la segunda mitad del siglo XX la estadística aprovecha la llegada del ordenador para construir nuevos métodos basados en el cálculo intensivo para hacer inferencias, como el *Bootstrap*, creado por Efron en 1979 o los métodos de Montecarlo, para simular datos y estimar modelos complejos. La estadística ha desarrollado en el siglo XX modelos muy eficaces para la predicción con datos agregados y bien estructurados cuando el número de elementos observados,  $n$ , es mucho mayor que el número de variables,  $p$ . Los métodos estadísticos tratan de modelar relaciones de causalidad entre las variables, por lo que sus modelos tienen la ventaja de una fácil interpretación. Por ello, se han aplicado en todos los campos del conocimiento y de forma muy destacada en economía, con técnicas específicas para variables económicas que han creado la econometría. En el campo de las finanzas tanto la estadística como la econometría han creado herramientas de análisis cuantitativo que han hecho avanzar nuestro conocimiento de los procesos financieros y de las decisiones de inversión.




La aparición en el siglo XXI de los datos masivos asociados a nuevos problemas produjo inicialmente un «espejismo del tamaño», es decir, el error frecuente de creer que si la dimensión de los datos aumenta, con más casos y variables, podemos aplicar, con pequeños ajustes, los mismos métodos desarrollados para pocos datos a los nuevos masivos. La ciencia nos ofrece muchos ejemplos de que esta extrapolación puede no funcionar. Por ejemplo, es bien conocido que al aumentar la velocidad de un objeto y aproximarse a la de la luz, la física clásica deja de ser aplicable y tenemos que utilizar las ecuaciones de la relatividad, donde el tiempo es relativo y depende de la velocidad. En el mismo sentido, al descender a la escala microscópica aparecen las propiedades cuánticas y principios como el de superposición, donde una partícula puede estar simultáneamente en dos posiciones distintas con cierta probabilidad, que desaparecen al aumentar el tamaño. Estos principios cuánticos, únicamente observables a escala de nanómetros, hacen posible la computación cuántica que puede revolucionar los métodos de computación futura. Como ejemplo más cercano a nuestra experiencia, un medicamento tomado en pequeñas dosis nos ayuda a dormir y en dosis elevadas nos produce la muerte. Hoy es generalmente aceptado que necesitamos nuevos métodos para algunos de los nuevos problemas y que la colaboración entre científicos de distinto origen (estadística, computación e ingeniería) es fundamental en la nueva disciplina de *data science* o ciencia de los datos (véase Peña, 2014 y 2015 y Galeano y Peña, 2019).

Los nuevos datos permiten abordar nuevos problemas, pero requieren también nuevos procedimientos. En primer lugar, y como hemos comentado, el número de variables explicativas posibles que podemos crear con ellos es enorme, y resumirlos en variables utilizables plantea serios problemas estadísticos. Antes, la estadística comenzaba analizando unos datos dados; ahora, debemos utilizarla para crearlos. Por ejemplo, supongamos que queremos prever una variable, por ejemplo, si un cliente va a devolver o no un crédito solicitado, y, además de la información habitual, disponemos de toda su historia en el banco y la información pública de su actividad en redes sociales. Resumir en variables operativas su trayectoria financiera descrita en un conjunto de series temporales es ya un problema complejo, como lo es también obtener de las redes sociales variables relevantes. Por ejemplo una variable podría ser la proporción de sus amigos que aparecen en ficheros de morosos, pero hay también

otras muchas variables posibles que podría construirse a partir de esta información. Además, estas variables pueden estar relacionadas entre sí, y para analizarlas conjuntamente podríamos construir una variable indicadora, combinación lineal de todas ellas. Por ejemplo, el IPC es una manera de resumir los gastos en distintos conceptos asignando a estas variables unos pesos que son su importancia en la cesta de la compra promedio. En general, no disponemos de los pesos que tenemos que dar a cada variable de un conjunto para definir una buena variable indicadora y estos pesos deben determinarse empíricamente a partir de los datos.

Un segundo problema es el de la heterogeneidad: la relación entre las variables puede no ser la misma para personas con distintos hábitos que se manifiestan en sus pautas de consumo o en su actividad en las redes sociales y debemos construir modelos distintos para clientes diferentes. Además, la relación entre dos variables puede depender de una tercera creando interacción o una relación no lineal entre ellas. Finalmente, los datos recogidos pueden tener errores de medida. Es frecuente que los sensores fallen por diversas razones (véase, Paradis y Han, 2007, para una panorámica de este problema) y sus fallos producen valores atípicos en los datos. Podría pensarse que los datos atípicos no son importantes cuando tenemos muchos datos, pero desgraciadamente no es así: podemos tener un millón de datos de dos variables y su correlación puede depender de un solo dato con un error de medida suficientemente grande. Esta situación se ilustra en el gráfico 1, donde la relación de dependencia entre las variables

**GRÁFICO 1**  
**UN ÚNICO PUNTO CREA LA CORRELACIÓN ENTRE DOS VARIABLES AUNQUE HAYA DIEZ MILLONES DE DATOS**



se genera por un único punto y se pone de manifiesto la necesidad de limpiar cuidadosamente los datos antes de cualquier análisis.

Los nuevos procedimientos para grandes masas de datos suelen agruparse bajo el nombre de *aprendizaje estadístico* (véase Hastie, Tibshirani y Friedman, 2009), y en su desarrollo la Universidad de Stanford ha tenido un papel de liderazgo. Estos nuevos métodos se diferencian de los tradicionales en: 1) utilizan criterios automáticos de selección de modelos y validación fuera de la muestra; 2) combinan muchos modelos simultáneamente para la predicción; 3) incluyen procedimientos iterativos de aprendizaje para mejorar el modelo con nuevos datos; 4) consideran relaciones no lineales entre las variables de tipo muy amplio, incluyendo estructuras en forma de árbol como los árboles de decisión (*Classification and Regression Trees*, *CART*, por sus siglas en inglés) y los bosques aleatorios (*random forest*). Sus resultados compiten en los últimos años con procedimientos desarrollados en *aprendizaje automático* (*machine learning*) y en *inteligencia artificial*, que comentaremos en el siguiente apartado.

### 3. Aprendizaje automático e inteligencia artificial

Se denomina *inteligencia artificial* (*artificial intelligence*, *AI*) la rama de las ciencias de la computación que desarrolla procedimientos para que las máquinas puedan comportarse con inteligencia humana. Por ejemplo, reconociendo el lenguaje y la visión y reaccionando en consecuencia, aprendiendo y resolviendo problemas. La robótica construye máquinas (robots) basados en estos métodos. Se denomina *aprendizaje automático* o *aprendizaje máquina* (*machine learning*, *ML*) a la parte de *AI* que desarrolla algoritmos para la predicción de una o varias variables utilizando una amplia base de datos observados que contiene valores de las variables a prever y de las variables explicativas que pueden utilizarse para la predicción. Aunque este objetivo es similar al que buscan los modelos estadísticos hay una diferencia importante: *ML* busca la mejor predicción de acuerdo con los datos observados, es decir, utiliza las correlaciones observadas de muchas variables para obtener buenas predicciones. Sin embargo, la estadística trata de construir un modelo comprensible, que incluya relaciones causales y que funcione bien no solo en los datos observados, sino en otros que puedan generarse en el futuro. Esta diferencia indica las ventajas y limitaciones de cada enfoque.

Los algoritmos de *ML* utilizan para construir la regla de predicción una técnica estadística llamada validación cruzada (*cross-validation*), que consiste en dividir los datos disponibles en dos partes. La mayor parte de ellos, unos 2/3 del total, se utilizan en una muestra de entrenamiento para estimar distintas reglas de predicción. Los datos no utilizados forman la muestra de validación, que se utiliza para seleccionar el mejor modelo entre los estimados en la muestra de entrenamiento. Como el resultado obtenido puede depender de la partición realizada, el proceso de división de la muestra en dos partes suele repetirse de nuevo y promediar los resultados tomando la regla que funciona mejor en promedio. Naturalmente, el tiempo de cálculo para seleccionar la regla de predicción es mucho mayor que en los modelos estadísticos tradicionales, pero en algunos casos los resultados son más precisos.

La forma de la regla de predicción de la variable respuesta en función de las variables explicativas (también llamadas variables *input* o variables de entrada) puede ser muy variada (véase Bishop, 2006). El método más utilizado habitualmente son las redes neuronales (*neural networks*, *NN*, por sus siglas en inglés), que son capaces de aproximar cualquier relación posible entre la respuesta y los *inputs*. Un problema frecuente de la regla obtenida es que la relación entre cada variable y la respuesta es muy compleja y no puede determinarse de forma simple. Por eso se denomina a estas reglas de predicción de «caja negra», ya que no es posible conocer fácilmente el efecto de cada variable explicativa en la respuesta. Además, el efecto de una variable puede depender de los valores de otras variables relacionadas con ella, con lo que comprender el efecto total de cada variable o grupos de variable requiere técnicas estadísticas de diseño de experimentos muy complejas (Galeano y Peña, 2019).

### 4. Implantación de los métodos de análisis

La implantación efectiva de los nuevos métodos de análisis requiere la infraestructura y el *software* necesarios para llevar adelante estos cálculos. Desde el punto de vista del *software* destacaremos la existencia de sistemas potentes para el cálculo en paralelo y el desarrollo de lenguajes de programación en código abierto, que facilita a los inventores de nuevos métodos programarlos y ponerlos al alcance de todos los interesados.

Los programas de cálculo estadístico han evolucionado de los trabajos por lotes a los programas

interactivos que permiten acceso directo a los resultados intermedios y capacidad de programación dentro del paquete (como en SAS, S+, SCA, MATLAB, GAUSS, etc.). Un avance fundamental han sido los lenguajes en código abierto orientados a objetos, que permiten manejar indistintamente funciones, variables o gráficos. La aparición de los lenguajes R y Python, nacidos en los años noventa, ha creado un estándar donde cientos de investigadores de todo el mundo incorporan nuevas rutinas ampliando cada día las capacidades de análisis. Véase Ugarte, Militino y Arnholt (2005) para el uso de R en estadística y Pedregosa *et al.* (2011) para Python en *machine learning*. Esto ha dado a ambos lenguajes una ventaja imbatible frente a otros que no se enriquecen continuamente por los nuevos paquetes escritos por miles de investigadores en todo el mundo. Los dos lenguajes pueden integrarse con distintas bases de datos e incorporan cálculos en paralelo, necesarios con las grandes bases de datos actuales.

Los datos masivos requieren computación en paralelo y distribuida, y el almacenamiento en la nube. El cálculo en paralelo consiste en ejecutar muchas instrucciones simultáneamente. Esto exige una programación donde un cálculo secuencial se descompone en partes que pueden realizarse en paralelo, sea en *hardware* con procesadores con varios núcleos o con varios procesadores que se comunican entre sí. Esta forma de trabajos muestra su potencia cuando se conectan varios ordenadores a la web, en general de forma remota sin proximidad física, formando un clúster, es decir un grupo de ordenadores conectados entre sí mediante un sistema de red de alta velocidad. Además, debe existir un programa que controle la distribución de la carga de trabajo entre los equipos. Por lo general, este tipo de sistemas cuentan con un centro de almacenamiento de datos único.

Una infraestructura digital en código abierto, dentro de la licencia de la Fundación APACHE, es Hadoop, creado por Doug Cutting. Hadoop combina la computación en paralelo y distribuida permitiendo desarrollar tareas muy intensivas de computación dividiéndolas en pequeñas partes y distribuyéndolas en un conjunto tan grande como se quiera de máquinas. Al ser de licencia libre este *software* está siendo adoptado no solo por usuarios particulares sino también por grandes sistemas (Oracle, Dell, etc.), lo que está llevando a una aceleración tanto de su difusión como de sus prestaciones. A diferencia de las soluciones anterior-

es para datos estructurados, la tecnología Hadoop introduce técnicas de programación nuevas y más accesibles para trabajar en almacenamientos de datos masivos con datos tanto estructurados como no estructurados.

### III. OPORTUNIDADES PARA LAS INSTITUCIONES FINANCIERAS

A continuación vamos a comentar algunas aplicaciones donde el uso del *Big Data* puede suponer ventajas para las instituciones financieras.

#### 1. Mejorar las predicciones mezclando distintos tipos de información: *nowcasting*

Tradicionalmente, la obtención de predicciones ha sido llevada a cabo utilizando información proporcionada de manera periódica, que incluye la generada por institutos nacionales o internacionales de estadística. De esta manera, para obtener predicciones, por ejemplo del producto interior bruto (PIB), es muy habitual utilizar modelos de series temporales tales como modelos vectoriales autorregresivos (VAR) o modelos de regresión dinámica, donde el futuro de una variable se explica utilizando, además de su historia, otro conjunto de series temporales, con la misma frecuencia o periodicidad y el mismo período de observación. Recientemente, muchas instituciones financieras han comenzado a utilizar para hacer predicciones sobre sus clientes otro tipo de información más compleja y que mezcla una amplia variedad de bases de datos estructuradas y no estructuradas. Esta información puede incluir desde el uso que los clientes hacen de Internet, las búsquedas en Internet más frecuentes, su actividad en redes sociales como Twitter o Instagram, o información sobre transacciones entre diferentes clientes de la institución. Estos datos tienen la ventaja de que, en la mayoría de los casos, pueden obtenerse en tiempo real, permitiendo la actualización instantánea de las predicciones.

Para realizar predicciones en este nuevo entorno, ha aparecido una nueva área de investigación llamada *nowcasting* que permite combinar series temporales con diferentes periodicidades con el objetivo de mejorar las predicciones. Su nombre es una contracción de *now* (ahora) y *forecasting* (predicción). *Nowcasting* se desarrolló en meteorología para predecir el clima futuro a muy corto

plazo (tres o seis horas, por ejemplo). Pretende pronosticar, con alta fiabilidad, determinados fenómenos meteorológicos, como puede ser una tormenta en una localización geográfica concreta. En economía, Giannone, Reichlin y Small (2008) utilizaron dicha técnica con el objetivo de evaluar el impacto marginal que las publicaciones de datos intramensuales tienen en los pronósticos del trimestre actual del crecimiento del PIB real. De esta manera, se utiliza información actual para predecir a un breve horizonte temporal. Un aspecto importante es que *nowcasting* permite actualizar las predicciones cada vez que se obtienen nuevos datos de forma no sincronizada. Para una revisión extensa de este campo, referimos a Kapetanios y Papaillias (2018), quienes presentan metodologías para realizar *nowcasting*, que incluyen: (1) métodos basados en *machine learning*, como regresiones penalizadas, regresiones *sparse* y métodos *boosting*; (2) (optimización) entre otros, optimización heurística de criterios de información, como *simulated annealing* o algoritmos genéticos; y (3) métodos basados en reducción de la dimensión, como componentes principales y sus versiones *sparse*, y métodos textuales.

Desarrollar nuevos procedimientos que permitan mezclar información procedente de nuevas fuentes, como textos, imágenes o vídeos, con información más tradicional es una necesidad urgente. Un ejemplo en finanzas lo podemos encontrar en Chen *et al.* (2014), quienes, para pronosticar el mercado de valores, combinaron información estándar con información obtenida en webs financieras. De manera similar, Bartov, Faurel y Mohanram (2018) demostraron que no solo la actividad de Twitter predice el mercado de valores en su conjunto, si no que la opinión agregada de los *tweets* individuales predice con éxito las próximas ganancias trimestrales y los retornos de anuncios de una empresa. Otro ejemplo lo podemos encontrar en investigación de mercados y en *marketing* donde empieza a ser necesario combinar la información más tradicional sobre los clientes, como su género o su edad, obtenida mediante el uso de cámaras y micrófonos que captan las reacciones de varios clientes ante un dependiente o por un producto. Similarmen-te, las compras realizadas por un cliente, por su frecuencia, y/o las similitudes con las hechas por otros clientes están guiando los llamados sistemas de recomendación, tan habituales ya en compañías de comercio electrónico tales como Amazon, AliExpress o Ebay, para hacer ofertas atractivas de productos que los clientes tienen altas probabilidad

des de comprar. Por ejemplo, en Amazon, líder de estos sistemas de recomendación, un tercio de sus ventas se atribuye a su efecto (Mayer-Schonberger y Cukier, 2013).

## 2. Predicciones personalizadas y geolocalización

El nuevo paradigma del *Big Data* está llevando a muchas compañías e instituciones a utilizar técnicas para personalizar sus predicciones. Por ejemplo, cada vez es más frecuente que un banco decida promocionar un producto a un determinado espectro de la población que tenga unas características específicas, como una hipoteca con unas condiciones ventajosas a todos sus clientes de entre 25 y 45 años, ya que en ese rango de edades es cuando la gran mayoría de personas decide comprarse una vivienda. Sin embargo, si solo se tiene en cuenta la edad es posible que la oferta publicitaria recibida por el cliente no sea de su interés, perdiendo la oportunidad de ofrecerle un producto más adecuado. Por ejemplo, una persona soltera que esté realizando estudios de posgrado, y que encaja perfectamente en ese rango de edades, posiblemente esté más interesada en un pequeño crédito que le permita comprar un equipo informático o realizar un viaje de vacaciones.

Conocer muchos datos de cada uno de los clientes puede ayudar a predecir mejor determinados comportamientos de consumo. En general, el éxito de las ofertas se incrementará al añadir aspectos que permitan realizar predicciones más personalizadas.

Un ejemplo de información relevante es la obtenida a través de la geolocalización que proporciona la ubicación exacta de un teléfono móvil, tablet o equipo informático. En base a ciertas coordenadas geográficas. El sistema de geolocalización más habitual es el denominado Sistema de Posicionamiento Global (*Global Positioning System*, *GPS*, por sus siglas en inglés). Este sistema es el que permite a determinadas aplicaciones que se pueden descargar desde cualquier teléfono móvil como Google Maps o Waze, conocer la ruta más rápida entre dos puntos geográficos concretos o planear rutas alternativas si durante el viaje, la ruta inicial deja de ser la más rápida debido a un atasco o un accidente de tráfico. El *GPS* no es el único sistema de geolocalización. Por ejemplo, se puede identificar la situación de un equipo informático a través de una



dirección de protocolo de Internet (*Internet Protocol*, *IP*), dirección de control de acceso a medios (*media access control*, *MAC*), o de otros sistemas de posicionamiento inalámbrico.

Conocer la geolocalización de un cliente es muy relevante en un gran número de aspectos. Un primer ejemplo es el de conocer cuándo un pago con una tarjeta de crédito es fraudulento o no. Por ejemplo, si un cliente realiza una compra desde una dirección *IP* de un país extranjero y el banco no tiene constancia de que el cliente esté en dicho país, por haber comprado un billete de avión con tarjeta de crédito o pagado una cuenta en el aeropuerto de la residencia habitual del cliente, lo más probable es que el banco determine que dicha compra es fraudulenta. La geolocalización del teléfono móvil también puede ser útil en este sentido ya que realizar un pago en un lugar diferente a donde está situado el teléfono móvil puede ser motivo para declarar la compra como fraudulenta. Un segundo ejemplo es el uso de la geolocalización de un cliente para conocer su entorno: donde vive, donde trabaja, donde va de vacaciones, etc. Esta información puede ser muy útil para ofertar productos de un determinado interés local u ofertas localizadas en lugares cercanos a los habituales lugares de movimientos del cliente. Un tercer ejemplo es que un banco puede dirigir a un cliente a la sucursal más próxima para la realización de trámites una vez se conecte a la banca *online* a través de su teléfono móvil. Un cuarto ejemplo es que un banco puede aplicar determinadas restricciones geográficas para la realización de operaciones o una compañía de venta *online* puede aplicar restricciones similares para el envío de determinados productos entre países para proteger los derechos de distribución.

### 3. Predicción del abandono de clientes (*churn or customer loyalty prediction*)

Debido al actual alto grado de competencia en todos los sectores, tan importante o más que intentar ganar clientes es retener los actuales. Su pérdida implica la ganancia de otros, y nuestra disminución de cuota de mercado. Además, un cliente enfadado difunde su descontento en redes sociales con mayor probabilidad que uno satisfecho, con efectos muy negativos sobre la imagen de la empresa. El término en inglés *churn rate* se refiere a la tasa de pérdida de clientes de una compañía o institución. Habitualmente, esta pérdida es pequeña, es decir, son

clientes aislados que dejan de utilizar los servicios de la compañía o institución para, o bien irse a la competencia, o bien dejar de utilizar el servicio para siempre. Claramente, es de interés de las compañías entender qué factores hacen que los clientes tomen dicha decisión para predecir cuando un cliente dejará de serlo (*churn prediction*).

Existe un número importante de procedimientos para predecir el abandono de clientes mediante el uso de técnicas de *machine learning*, que utilizan tanto información propia de las compañías, como información externa. Por ejemplo, De Bock y Van den Poel (2011) comparan métodos de clasificación supervisada de clientes activos y clientes perdidos de varias compañías, incluyendo *random forest* y sus variantes como *AdaBoost*, con otras técnicas para la extracción de características, incluyendo análisis de componentes principales, análisis de componentes independientes y proyecciones aleatorias. Estos autores ilustran que el uso de combinaciones de clasificadores parece determinar muy bien qué características de los clientes son las que mejor determinan el abandono. Benoit y Van den Poel (2012) investigan el uso de información proporcionada por redes de clientes de servicios financieros para la retención de los mismos. Para ello, los autores investigan si además de los conjuntos convencionales de variables, sociodemográficas, historial de compras, etc., las variables basadas en la red de clientes mejoran el poder predictivo de modelos de retención de clientes. La principal conclusión obtenida es que el poder predictivo de un modelo de abandono se puede mejorar agregando variables basadas en redes sociales. Por ejemplo, la inclusión de determinadas características de una red, por ejemplo, el número de relaciones de un cliente, la importancia del cliente dentro de la red o la densidad de la propia red, aumenta la precisión predictiva. De hecho, las variables basadas en la red pueden tener mayor impacto en discriminar clientes que abandonan de los que no, que el resto de variables. Este y otros aspectos relacionados con redes de clientes serán tratados con mayor detalle en la siguiente subsección y en el ejemplo con datos reales de la sección cuarta.

Por último, Burez y Van den Poel (2008) demostraron que se puede predecir con mayor precisión la pérdida de clientes que se van a la competencia, o dejan de utilizar el tipo de servicios ofertados por la compañía, que su pérdida por morosidad.



#### 4. Utilizar la red de clientes para orientar políticas

La red de clientes de una institución financiera, como puede ser un banco, es una fuente de información muy importante en varios aspectos. En primer lugar, es una pieza fundamental para entender la importancia de sus usuarios analizando su posición en dicha red. Tradicionalmente, se ha tendido a considerar que la importancia de un cliente se mide a partir de sus recursos económicos. Esta medida ignora su importancia estratégica dentro de la institución y su posición y relaciones en el conjunto de la red de clientes. La importancia de un cliente depende, claramente, de las consecuencias para el banco de que deje de serlo.

En el análisis estadístico de redes encontramos varias maneras de medir la importancia de un vértice (cliente en este caso) en función de sus relaciones con otros vértices (otros clientes) para medir el efecto de que un vértice desaparezca de dicha red. Por ejemplo, una primera opción es considerar que un cliente puede ser importante si está relacionado con muchos otros clientes. Esto es relevante para un banco ya que este cliente puede tener una influencia importante sobre muchos otros y puede actuar como elemento transmisor de los productos del banco. Si el cliente dejara de serlo, se perdería dicho elemento transmisor. Una segunda opción es que lo sea si está cerca de muchos otros clientes. En este caso no sería necesario que el cliente tenga relación directa con muchos otros, sino que bastaría con que cualquier camino que debería recorrer el cliente para llegar a cualquier otro de la red fuese pequeño. De nuevo, este tipo de clientes deberían ser relevantes ya que si desapareciesen la distancia entre clientes aumentaría. Una tercera opción es que sea importante si es necesario cruzar por él frecuentemente para conectar unos clientes con otros. De nuevo nos encontramos con un cliente que puede actuar de catalizador entre muchos otros. Si el banco quiere ofertar un nuevo producto, este tipo de clientes son especialmente relevantes para extender la oferta entre muchos otros clientes.

En segundo lugar, la red de clientes es una pieza fundamental para captar la presencia de grupos de clientes cohesionados (con fuertes relaciones entre ellos). Conocer la presencia de estos grupos es muy relevante para orientar determinadas políticas. Por ejemplo, si un banco conoce un conjunto de clientes cohesionados, se podrían analizar las caracte-

rísticas específicas de dicho grupo (por ejemplo, si son todos padres de niños de un mismo colegio o de un club deportivo, o un grupo de personas que realizan actividades conjuntas), y crear productos específicos apropiados para ellos. Sería también de interés localizar los clientes más importantes dentro de la subred creada por ese grupo para conocer que cliente sería idóneo para la posterior propagación de dichos productos.

Determinar la presencia de grupos de clientes fuertemente enlazados se conoce con el nombre de detección de comunidades. El problema consiste en obtener una partición de la red en varias subredes de tal manera que los miembros de cada una de las subredes tuviesen una fuerte relación entre ellos y escasa con los miembros de otras subredes. Una medida de la calidad de una partición es la modularidad que se define como la suma para cada una de las subredes de las diferencias entre el número de relaciones dentro de la subred con respecto al número esperado de relaciones si no hubiese tal estructura de comunidades. Cuanto mayor sea el valor de la modularidad de una red, más significativa será la presencia de los grupos. Existen diferentes algoritmos que tratan de proporcionar particiones de la red con máxima modularidad. Posiblemente el más popular de ellos es el conocido como método Louvain (véase Blondel *et al.*, 2008), debido a que fue propuesto por varios investigadores de la Universidad Católica de Lovaina. El método consiste en resolver el problema de maximizar la modularidad mediante un método conocido como *greedy optimization*. La ventaja fundamental de este procedimiento sobre otros propuestos, ver Clauset, Newman y Moore (2004) y Brandes *et al.* (2008) entre otros, es que el problema de optimización se puede resolver para un número muy grande de vértices y relaciones, tan grande como varios millones de cada una de ellas. Otro tipo de procedimientos algo menos utilizados es el uso de clustering jerárquico, muy habitual en el análisis de datos multivariantes. La idea de este tipo de procedimientos en redes, denominados algoritmos *walktrap* (véase Pons y Lapaty, 2005), es calcular distancias entre diferentes vértices (clientes) y aplicar clustering jerárquico sobre estas distancias para poder crear los grupos.

En tercer lugar, la red de clientes también puede ser utilizada para explicar y predecir determinados comportamientos de los clientes. Un ejemplo ilustrativo es la mora. Explicar las razones por las que los clientes entran en mora es *a priori*

un problema complicado. Una opción es utilizar la información personalizada del cliente, como su edad, su estado civil, su salario y el total familiar, su situación laboral, su lugar de residencia, la deuda contraída con el banco, los productos contratados por el mismo, etcétera. Sin embargo, la situación del cliente dentro de la red puede ser un aspecto fundamental para explicar las razones que hacen que un cliente entre en mora. Supongamos, por ejemplo, el trabajador de una empresa que entra en suspensión de pagos. Si el trabajador tiene una hipoteca con el banco, muy probablemente en los próximos meses entrará en mora ya que no recibirá su salario. Evidentemente otros factores pueden ser importantes, como los mencionados previamente, pero este hecho fundamental puede ser determinante para la entrada en mora del trabajador. El banco dispone de dicha información, puede utilizar mecanismos para evitarlo. En general, un aspecto importante para predecir la entrada en mora de un cliente es sus relaciones con otras personas en mora o que pueden estarlo a corto plazo. Para ello, es necesario que los analistas del banco realicen un análisis temporal de los datos. Por ejemplo, se pueden tomar diferentes momentos temporales de la información de los clientes, por ejemplo un mes, incluyendo su situación dentro de la red de clientes y cuáles de los clientes en dicha red están en mora. Con esta información, se pueden construir procedimientos de clasificación supervisada que permitan explicar qué variables son las más relevantes para explicar la mora de los clientes y con esta información construir procedimientos estadísticos que permitan predecir dicha mora a corto o medio plazo. Un ejemplo de este tipo de análisis se puede encontrar en la sección cuarta de este artículo donde podremos comprobar la efectividad de este tipo de análisis.

En cuarto lugar, una red formada por clientes y por no clientes de un banco puede ser útil para la captación de nuevos clientes. Para ello, un gestor de un banco puede contactar con uno de los clientes de su cartera y a través de quien podría contactar consecutivamente con otros clientes del banco que no estén en su cartera y que le permitan tener las mejores opciones para poder contactar y convencer a un potencial nuevo cliente. Para ello, el gestor debe tener algún tipo de herramienta que le permita construir el camino que le lleve al éxito con mayor probabilidad de entre todos los posibles caminos contruidos a partir de las relaciones entre clientes. Para ello, una opción

es determinar la probabilidad de tener éxito en cada una de las etapas del camino, es decir, de tener éxito en contactar a un cliente a partir de su relación con otro. Con todas estas probabilidades calculadas el camino óptimo de entre todos los posibles puede ser aquel que maximice el producto de las probabilidades asociadas a cada una de las relaciones. El cálculo de estas probabilidades puede depender de un número importante de aspectos como pueden ser la confianza o el vínculo entre los clientes, la satisfacción de los clientes con el banco, la influencia que puedan tener los clientes involucrados y la personalidad o el grado de conformidad de los mismos, entre otros aspectos, ver Quijano-Sánchez y Liberatore (2017). Evidentemente, estos conceptos son subjetivos y deben ser cuantificados de alguna manera. Para ello, es posible llevar a cabo una cierta estimación de cada uno de estos aspectos con la información que el banco posee de los clientes. Un ejemplo práctico de este tipo de análisis junto con una propuesta para el cálculo de las probabilidades de éxito basados en los aspectos descritos previamente se puede encontrar en el ejemplo de la sección cuarta.

Por último, dadas las múltiples relaciones en una red de clientes es necesario tener en cuenta todas las características de los clientes. No puede ser igual una relación consistente en un pago puntual por la venta de un coche de segunda mano, que otra que implica transferencias periódicas por una cantidad importante. Las relaciones entre clientes deben ponderarse de acuerdo a los objetivos del análisis de la red. Por ejemplo, hay que considerar: 1) el tipo de clientes que definen la relación, es decir, cuando los clientes son personas, entidades, representantes, etc.; 2) la dirección de la relación, es decir, si una empresa paga a un empleado, o un arrendado paga un alquiler al arrendatario, etc.; 3) el número de relaciones entre los clientes, es decir, si existe un único movimiento o existe un número repetido de movimientos; y/o (4) la cantidad económica transferida. Un ejemplo de estas ponderaciones se presentará en la sección cuarta.

## 5. Prevenir y detectar el fraude

El aumento de las operaciones de pago con medios digitales, tarjetas, teléfonos móviles, etc. ha generado nuevas formas en que los delincuentes pueden cometer fraudes. Cómo prevenir y detec-

tar fraudes financieros ha sido un amplio campo de investigación en los últimos veinte años. Véase Bolton y Hand (2002), Kou *et al.* (2004), Phua *et al.* (2010) y Abdallah, Maarof y Zainal (2016), para una revisión de los tipos de fraude y los métodos para prevenirlos y detectarlos.

Los dos tipos de fraude financiero más importantes en la actualidad son el fraude a través de compras con tarjeta de crédito y mediante la utilización fraudulenta de la cuenta bancaria. La utilización de las tarjetas de crédito ha crecido mucho en los últimos tiempos y también el fraude, aunque el uso creciente de técnicas de prevención y detección parecen haber detenido ese avance: El Banco Central Europeo en su último informe de 2018 (<https://www.ecb.europa.eu/pub/cardfraud/html/ecb.cardfraudreport201809.en.html>), estima que este fraude ha sido en 2016 de 1,8 billones de euros en el *Single Euro Payments Area*. El fraude estuvo aumentado fuertemente desde 2012 a 2015, pero se ha estabilizado en los últimos años, representando un crecimiento del 14,8 por 100 comparado con el de 2011. Respecto a la composición del fraude, el más frecuente (73 por 100) corresponde a pagos no presenciales realizados por Internet o teléfono, 19 por 100 a pagos con la tarjeta en la venta y 8 por 100 a transacciones al sacar dinero con la tarjeta. Además, los pagos por medios no tradicionales, como el teléfono móvil o Internet, suponen ya el 60 por 100 de fraude cuando en 2008 era del 46 por 100. El mercado ha empezado a desarrollar herramientas para la prevención del fraude y su detección, al mismo tiempo que los gobiernos han revisado la normativa sobre las transacciones electrónicas (en la Unión Europea el *Payment Services Directive* (PSD2) de 2015 y el *Regulatory Technical Standards* en 2017).

Los primeros métodos utilizados a finales del siglo pasado para la detección del fraude fueron métodos de discriminación o de aprendizaje supervisado, en la terminología de *machine learning*. Estos métodos requieren tener una base de operaciones que se sabe han sido correctas y otra base de datos de operaciones fraudulentas. Ambos grupos se caracterizan por un conjunto de variables y se calcula la media de estas variables en ambos grupos. Cuando se observa una operación se calcula su distancia a ambos grupos y se clasifica en el más próximo. La comparación puede hacerse respecto a las medias, como en la discriminación lineal o logística, o respecto a todos los miembros de cada grupo, como los métodos no paramétricos de veci-

nos más próximos. En este siglo se introdujeron métodos no lineales con variables cualitativas como los árboles de decisión (CART), los bosques aleatorios (*random forest*), las redes neuronales (NN) y las máquinas de vector soporte (*vector support machines*). Los bancos no proporcionan información precisa de los métodos utilizados pero uno muy popular es el desarrollado por FICO (Fair&Isaac Cooperation), que asegura que su *Falcon Fraud Manager*, basado en NN, se utiliza en más de la mitad de las transacciones mundiales (véase Maruaton, Vamplew y Dazeley, 2012). En España, Dorronsoro *et al.* (1997) crearon un sistema de detección, también basado en NN, ampliamente utilizado.

Los métodos supervisados o de discriminación se han aplicado con éxito a las operaciones con tarjetas de crédito, pero son menos útiles para los fraudes en cuenta corriente donde no siempre disponemos de los dos conjuntos de datos buenos y fraudulentos. Además, el tipo de operaciones fraudulentas puede ser muy amplio, y cambiante en el tiempo. Por ejemplo, si el posible fraude es realizar una transferencia a una cuenta controlada por el delincuente, no dispondremos en general de una base de transferencias fraudulentas hechas en condiciones similares para clasificar una nueva solicitud. Este tipo de fraude se detecta mejor con métodos de aprendizaje no supervisado, que incluye los métodos de identificación de datos anómalos y de detección de grupos, y que se utilizan cuando tenemos que basarnos únicamente en una secuencia disponible de transacciones, presumiblemente no fraudulentas. Los métodos que se utilizan se basan en comparar la transacción con las históricas y determinar la probabilidad de que la transacción sea significativamente diferente de las anteriores.

La disponibilidad de mucha más información respecto al uso de la tarjeta y los hábitos y características de su propietario permiten detectar mejor las operaciones fraudulentas pasando de modelos generales de detección del fraude a modelos específicos para cada tipo de cliente, en función de su situación. Además, el estudio de los datos pasados permite prever el tipo y características del defraudador que suele estar asociado a un tipo de cliente. También, se hace una graduación más fina de la probabilidad de que la operación sea fraudulenta, de manera que cuando esta probabilidad sea baja se acepte, cuando sea dudosa se consulte con el cliente y cuando sea alta se rechace y se notifique la situación de riesgo al cliente. El *Big Data* permite

especializar mucho mejor la población de referencia para cada cliente, incorporando no solo su propia actividad, sino la de personas con características similares a las suyas, generando una información mucho más precisa para la detección instantánea del fraude.

#### IV. UN EJEMPLO DE ANÁLISIS DE REDES DE CLIENTES

Esta sección presenta algunos resultados derivados del estudio de diferentes redes de clientes del Banco Santander (BS en adelante) desarrollado por varios miembros del Instituto Mixto UC3M-BS en *Big Data* de la Universidad Carlos III de Madrid (IBiDat en adelante) con el objetivo de ilustrar en un caso concreto algunas de las oportunidades del uso de información del *Big Data* para instituciones financieras descritas en la tercera sección.

##### 1. Objetivos del proyecto

El objetivo del proyecto consistía en determinar si la información contenida en diferentes redes de clientes del BS y en la estructura de sus relaciones es de utilidad para mejorar las políticas comerciales del banco. Los resultados del proyecto demostraron que la respuesta es claramente afirmativa: en primer lugar, disponer de la red de clientes permite clasificarlos mejor por su importancia; segundo, utilizar la red mejora la captación de nuevos clientes; en tercero mejora la predicción de la morosidad.

Durante el proyecto se ha elaborado un método para determinar el camino óptimo que debe seguir un gestor para contactar con un potencial nuevo cliente que tenga relaciones con clientes del BS y que será brevemente detallado posteriormente. Además, se ha comprobado que la información contenida en las redes de clientes es muy útil para explicar la evolución financiera de clientes en mora.

##### 2. Datos disponibles

Para poder construir y analizar las diferentes redes de clientes del BS, fue necesario trabajar con grandes bases de datos proporcionados por el BS de sus clientes en España y de las relaciones de dichos clientes con otros (clientes y no clientes). Esta información ha estado disponible en tres momentos temporales separados en seis meses. Más concretamente, el BS nos permitió trabajar con

cinco bases de datos de ámbito nacional correspondientes a: 1) relaciones entre clientes y no clientes; 2) perfiles de clientes y no clientes incluidos o no en la base de datos anterior; 3) importes de mora de clientes españoles; 4) datos de gestores-clientes; 5) datos de no clientes objetivos y de sus perfiles. Estas bases de datos fueron depuradas y estructuradas para construir diferentes redes de clientes necesarias para los objetivos propuestos. Es importante resaltar que para poder utilizar toda la información relevante fue necesario preservar el anonimato de los clientes, prestar una atención extrema a la confidencialidad de la información, y tener el máximo respeto a la Ley de Protección de Datos.

Vamos a resumir brevemente algunas de las variables que aparecen en estas bases de datos. En primer lugar, nos vamos a centrar en la base de datos de perfiles de clientes y no clientes. Esta base de datos se estructura en un conjunto de filas y columnas, donde cada fila corresponde a un cliente y cada columna son valores de variables asociadas a cada cliente. Algunas de estas variables son:

- El tipo de persona, es decir, si es física, jurídica, compañía, etc.
- El código de cliente.
- La presencia de mora o no en cada uno de los tres períodos analizados.
- El importe de la mora en cada uno de los tres períodos analizados.
- La edad del cliente.
- La ocupación del cliente.
- El segmento al que pertenece el cliente.
- El grado de vinculación del cliente con el BS en cada uno de los tres períodos analizados.
- Los recursos que tiene el cliente en el BS.
- El dinero del cliente en cuentas corrientes del BS.
- La deuda del cliente en hipotecas, préstamos al consumo, etc.
- Muchas variables dicotómicas, del tipo: si tienen nómina domiciliada en el BS, si disponen de tarjetas del BS, si tiene recibos domiciliados, si utiliza banca por Internet/móvil, etc.



La base de datos de relaciones entre clientes y/o no clientes del BS se estructura en un conjunto de filas y columnas, donde cada fila proporciona información sobre la relación entre un cliente y un cliente/no cliente del BS y cada columna proporciona variables como:

- Los códigos identificativos de los sujetos que forman la relación.
- El sentido en el que se debe leer un registro.
- El tipo de relación entre los sujetos.
- La intensidad de la relación.
- Las fechas de primera y última relación en el período considerado.

Las bases de datos sufrieron un fuerte preprocesamiento antes de poder construir las diferentes redes utilizadas en el proyecto. Por ejemplo, se realizó una tarea de limpieza para que en la red solo aparecieran los clientes con relaciones y/o que estén en carteras de gestores. Adicionalmente se substituyeron datos faltantes correspondientes a exclientes que aparecen en las relaciones con datos admisibles. También se eliminaron operaciones no deseadas entre clientes, clientes irrelevantes, relaciones repetidas entre clientes y relaciones entre clientes no relevantes para los objetivos del estudio.

El preprocesamiento ha reducido el tamaño de los datos finalmente utilizados, aunque sigue siendo enorme. Por ejemplo, la red de clientes construida para la captación de nuevos clientes contiene 6.329.506 relaciones entre 4.783.145 clientes relevantes, una reducción importante de la base de datos inicial que contenía 81 millones de relaciones entre 33 millones de clientes y no clientes.

### 3. Análisis descriptivo de la red de clientes

Como hemos comentado en el apartado cuatro de la tercera sesión, una red es un objeto llamado grafo formado por vértices y aristas. En nuestro caso particular, los vértices del grafo (red) serán los clientes (personas, empresas, organizaciones y demás clientes) del BS, y las aristas representan relaciones o flujos entre dichos clientes. Para realizar un análisis descriptivo de la red se utilizan varias características, incluyendo medidas que midan la centralidad (importancia) de los clientes con el objetivo de cuantificar las relaciones de poder, pro-

tagonismo, confianza, etc., y la detección de comunidades específicas que puedan tener características interesantes a señalar y estudiar.

El primer paso del análisis es crear el grafo que represente la red de interés. Para ello, y tal como se ha mencionado previamente, se utilizaron las bases de datos relativas a las operaciones entre clientes y la descripción de clientes descritas en el punto 2 anterior. En este grafo, cada vértice representará un cliente del BS y cada arista representará al menos una relación entre dos clientes. Además, cada arista está valorada por un peso que toma valores en el intervalo  $[0,1]$ , para representar la cercanía entre los clientes que une, de nuevo en función de la red creada. Por tanto, un peso próximo a 1 representa una gran cercanía entre los dos clientes. Un ejemplo de definición de peso se describe en el apartado 4, donde se describe la determinación de caminos óptimos.

Una vez construida la red, el siguiente paso es la obtención de sus componentes conexas. Una componente conexa de una red es una subred, es decir, una parte de la red, en la que todos sus vértices están conectados a través de trayectorias entre las relaciones que forman la subred, y a la que no se pueden añadir más vértices que cumplan dicha propiedad. Si la mayor componente conexa del grafo incluye una fracción muy significativa del mismo, se la denomina componente gigante. El resto de componentes se denominan componentes aisladas. En el caso particular de la red construida para la captación de nuevos clientes, existe una componente gigante de 4.783.145 clientes y 6.329.506 relaciones, frente a los 604.020 clientes y 302.010 relaciones que pertenecen a relaciones aisladas entre ellos, es decir, relaciones entre dos clientes totalmente aislados del resto de la red. Por tanto, el resto del análisis se puede concentrar en dicha componente gigante mientras que los clientes aislados pueden ser identificados por el BS para diseñar estrategias para fidelizar a estos clientes periféricos.

El siguiente paso es obtener medidas de centralidad de los clientes ya que nos sirven para conocer que clientes son los más importantes dentro de la componente gigante de la red. Como se mencionó en la sección tercera, hay diferentes opciones para definir centralidad, siendo la más popular el grado definido como el número de relaciones coincidentes con dicho cliente ponderadas por el peso de cada una de las relaciones. Es razonable pensar que los vértices con más enlaces son vértices centrales de la



red. Sin embargo, hay que tener en cuenta que el grado solo mide la importancia con respecto a los clientes más cercanos. Es decir, se asume que las conexiones de los clientes no importan, solamente importa las relaciones directas con los vecinos. Una segunda opción es la centralidad por vector propio o *eigenvector* que proporciona un mayor valor a aquellos clientes que están conectados a muchos clientes que a su vez están bien conectados en este sentido, y por tanto son buenos candidatos a difundir información útil para el BS. De esta manera se tiene en cuenta tanto la cantidad como la calidad de las mismas relaciones.

El histograma mostrado en el gráfico 2 muestra el logaritmo del valor de la centralidad por vector propio de la red de clientes del BS que sugiere tres grupos de clientes distintos de más a menos importantes: 1) un grupo con alto valor de la log-centralidad, entre -10 y 0; 2) un grupo con valor medio de log-centralidad, entre -10 y -38 aproximadamente; y 3) un grupo con valores bajos de log-centralidad, por debajo de -38. Evidentemente, el grupo formado por los clientes más importantes es el menos numeroso, mientras el grupo que engloba a una mayor cantidad de clientes es el de importancia intermedia. De esta manera, el BS puede identificar qué clientes son los más relevantes y estudiar posibles acciones que permitan su retención.

El siguiente paso del estudio descriptivo de la red es la detección de comunidades. Las redes complejas, como la estudiada, tienden a mostrar una alta concentración de enlaces en ciertas regio-

nes del grafo (comunidades o clústers), y una baja concentración de enlaces fuera de esas regiones. Esta propiedad suele darse como consecuencia de la heterogeneidad global y local de la distribución de los enlaces en un grafo. Por tanto, las comunidades o clústers se definen como grupos de vértices densamente conectados que presentan conexiones dispersas entre sí. Como se definió en la tercera sección, la modularidad es una medida con valor en el intervalo  $[-1, 1]$  que mide la presencia de los grupos. Cuanto mayor sea el valor de la modularidad de una red, más significativa será la presencia de los grupos. En este caso, el valor de la modularidad es 0.8452562, por lo que la red está claramente formada por comunidades. Utilizando el algoritmo de partición de comunidades de Louvin mencionado, en la sección tercera, se han detectado 119.389 comunidades. El histograma mostrado en el gráfico 3 muestra la distribución de los tamaños de dichas comunidades. La gran mayoría de las comunidades tiene un tamaño muy pequeño. Un estudio de cada comunidad permite investigar sus características e identificar los factores que relacionan los clientes que las componen. Esta información se podría aprovechar, por ejemplo, para el diseño de campañas y productos financieros del BS para cada comunidad.

#### 4. Captación de clientes

A continuación mostramos una metodología desarrollada para apoyar a los gestores de clientes del BS en su tarea de captar nuevos clientes y recursos. Esto incluye la atracción al BS de personas que no son clientes, pero también, la intensificación de la colaboración entre los clientes y el BS. A partir de

GRÁFICO 2

##### HISTOGRAMA DEL LOGARITMO DE LAS CENTRALIDADES DEL VECTOR PROPIO O EIGENVECTOR




GRÁFICO 3

##### DISTRIBUCIÓN DEL TAMAÑO DE LAS COMUNIDADES EN LA RED



una red de clientes y no clientes, los perfiles de los clientes y las carteras de los gestores, el método indica una colección de posibles caminos óptimos para llegar al cliente objetivo a través de sus contactos con clientes del BS. Dichos caminos óptimos se originan en el gestor y utilizan su cartera de clientes.

El objetivo es determinar la secuencia de personas clientes del BS que un gestor tiene en su cartera y que debería contactar para poder llegar a un potencial cliente que se define como objetivo. Supongamos, por ejemplo, que un gestor quiere conectar con un cliente objetivo a través de tres clientes en su cartera que, a su vez, se relacionan con otros clientes que pueden conducirle al cliente objetivo. Cada relación entre clientes lleva asociada un peso que represente la probabilidad de éxito del gestor. Por lo tanto, suponiendo independencia entre las diferentes relaciones, la probabilidad de éxito de cada uno de los caminos posibles se puede obtener como el producto de las probabilidades de éxito de cada relación utilizada.

Dicho lo anterior, el problema a resolver es: dados unos clientes iniciales (los que forman la cartera de clientes del gestor) y un objetivo, y contando con los miembros de la red de clientes del BS que están conectado con los clientes iniciales (la cartera de clientes del gestor), se desea determinar el camino hacia el objetivo con la mayor probabilidad de éxito. Para encontrar la solución deseada son necesarias tres etapas: 1) construir la red propia del cliente objetivo, que es aquella que contiene todas las conexiones de los clientes de la cartera del gestor con el cliente objetivo; 2) estimar la probabilidad de éxito de cada posible camino; y 3) seleccionar entre los caminos posibles el de máxima probabilidad de éxito. Dado que la red construida con todos los clientes que permiten alcanzar el cliente objetivo puede ser muy extensa e incluir caminos muy largos, parece adecuado fijar un número máximo de clientes por los que se debe pasar para llegar al objetivo.

La asignación de las probabilidades de éxito de cada una de las relaciones es la clave del método. Supongamos que queremos determinar la probabilidad de éxito entre un cliente  $i$  y un cliente  $j$ ,  $p_{ij}$ , que puede representar, por ejemplo, que el cliente  $i$  influya positivamente al cliente  $j$  acerca de un producto del BS, o que el no cliente  $j$  se convierta en cliente por la interacción con el cliente  $i$ . Para determinar esta probabilidad  $p_{ij}$  se han considerado cuatro factores que parecen determinar la influen-

cia de una persona sobre otra (ver Masthoff y Gatt, 2006). Estas son:

- La confianza entre las dos personas (también referido como la fuerza del vínculo). Definiremos la variable  $tie_{ij}$ , (*tie strength*, o confianza), entre  $i$  y  $j$ .
- La satisfacción del posible influenciador ( $i$  en nuestro caso) con el objeto a recomendar (el banco en sí o un producto de este). Lo caracterizaremos con la variable  $sat_i$ , que mide la satisfacción aparente del cliente  $i$  con el BS.
- La influencia que tiene  $i$  sobre  $j$  (o sobre la red de usuarios en general, su autoridad). Definiremos la variable  $aut_i$ , influencia de  $i$ , o capacidad de persuasión.
- La facilidad con la que el (potencial) cliente ( $j$ ) puede ser persuadido, es decir, su tipo de personalidad o grado de conformidad. Se caracteriza mediante la variable  $per_j$ , *personality* de  $j$ , o grado de conformidad.

Para calcular el valor de la variable  $tie_{ij}$  utilizamos el artículo de Granovetter (1973) quien define la *fuerza del vínculo* como una combinación lineal de cuatro factores: cantidad de tiempo, intensidad emocional, intimidad y servicios recíprocos que caracterizan el vínculo. Siguiendo estas definiciones, podemos definir el *tie strength* como la combinación de: 1)  $time_{ij}$ , el tiempo que  $i$  y  $j$  han estado interactuando; 2)  $intensity_{ij}$ , la intensidad de las transacciones entre  $i$  y  $j$ ; 3)  $intimacy_{ij}$ , el estado de estar en una relación privada o íntima; y 4)  $reciprocal_{ij}$ , situación en la que  $i$  y  $j$  se prestan servicio mutuo. En resumen y sin entrar en los detalles concretos para preservar información confidencial: 1) la variable  $time_{ij}$ , se calcula como el tiempo (años, meses) durante el cual  $i$  y  $j$  han estado interactuando mediante transacciones a través del BS; 2) la variable  $intimacy_{ij}$ , se calcula asignando un peso a la intensidad de las relaciones entre dos vértices  $i$  y  $j$ ; 3) la variable  $intensity_{ij}$  se calcula como el peso máximo entre las operaciones entre  $i$  y  $j$  dividido por el rango de los pesos; y 4) La variable  $reciprocal_{ij}$  toma el valor 1, si hay relaciones recíprocas, es decir existen relaciones de  $i$  a  $j$  y de  $j$  a  $i$ , y el valor  $reciprocal_{ij} = 0,5$ , si las relaciones son unidireccionales. A continuación, se construye una combinación lineal de estas cuatro variables para ciertos pesos, lo que nos permite determinar el valor de la variable  $tie_{ij}$ .

Para calcular el valor de la variable  $sat_i$  utilizamos el compromiso del cliente con el BS, para lo que damos diferentes pesos según el nivel de compromiso con el banco.

Para calcular el valor de la variable  $aut_i$  utilizamos el valor de diferentes medidas de centralidad del cliente. Por ejemplo, podemos definir:

$$inf_i = (grado_i - \min Grado_G) / (max Grado_G - \min Grado_G), \quad [1]$$

donde G es la red total tomada como no dirigida y sin repetición de aristas,  $\min Grado_G$  y  $max Grado_G$  son el grado mínimo y máximo en la red, respectivamente, mientras  $grado_i$  es el grado del nodo i.

Para calcular el valor de la variable  $per_i$  hay que tener en cuenta que no existe información de la misma para los no clientes. Sin embargo, para un cliente podemos interpretar este atributo como el éxito que ha tenido hasta ahora el BS en vender productos a este cliente, por lo que podemos interpretar  $per_i$  como la satisfacción y definirla como vimos anteriormente.

Una vez definidas todas las variables, se supone por sencillez que la probabilidad  $p_{ij}$  es una combinación lineal de estas cuatro variables tal que:

$$p_{ij} = peso\_tie * tie_{ij} + peso\_sat * sat_i + peso\_per * per_i + peso\_aut * aut_i \quad [2]$$

para unos ciertos pesos,  $peso\_tie$ ,  $peso\_sat$ ,  $peso\_per$  y  $peso\_aut$ . Como se mencionó previamente, una vez calculados todos los pesos necesarios, la probabilidad de éxito de un camino P se calcula como el producto de las probabilidades  $p_{ij}$  de todas las aristas (i, j) pertenecientes a P. Por tanto, el camino óptimo será aquel que maximiza el valor de dicho producto. Para ello, se requiere la resolución de un problema de optimización tal como se describe en Quijano-Sánchez y Liberatore (2017).

## 5. Mejora de la predicción de mora con variables de red

El tercer y último punto que vamos a considerar es el de tratar de explicar la mora de los clientes del BS con la ayuda de ciertas variables construidas con determinadas características de la red. Para ello, se han construido modelos para explicar la mora en dos momentos temporales separados por seis

meses utilizando un conjunto amplio de variables que incluyen el uso de los servicios del BS, los recursos del cliente, sus relaciones en la red de clientes y los cambios en estas variables durante el período considerado.

Presentamos a continuación la metodología utilizada y un breve resumen de las variables explicativas seleccionadas. Hemos utilizado regresión logística para explicar la variable mora por dos razones principales: 1) este modelo permite determinar la importancia de cada una de las variables utilizadas para explicar la variable respuesta lo que permite explicar mejor la morosidad de los clientes del BS y medir sus efectos en términos de la probabilidad de mora; y 2) este modelo ha demostrado su utilidad en problemas similares.

La variable mora describe si un cliente es moroso (valor igual a 1) o no moroso (valor igual a 0), y está disponible para tres momentos temporales que vamos a denominar, M1, M2 y M3, respectivamente, separados seis meses cada uno de ellos. Nos centramos en explicar: 1) la variable mora en M2 con información disponible en el período M1-M2; (2) la variable mora en M3 con la información disponible en el período M2-M3; y (3) la variable mora en M3 con la información disponible únicamente en M2. Los experimentos 1 y 2 requieren modelos explicativos y de predicción a corto plazo, ya que calculan la probabilidad de mora de un cliente hoy utilizando la situación financiera actual y pasada del cliente. El experimento 3 requiere un modelo de predicción con horizonte de seis meses.

Los modelos se han construido para distintas clases de clientes que resultan de segmentarlos por el tipo de persona («Autónomos», «Empresas» y «Físicas») y cuatro categorías diferentes de su vinculación con el BS, muy fuerte, fuerte, media y baja. Por tanto, se obtienen doce clases de clientes (desde «Autónomos con vinculación muy fuerte», AMF, hasta «Físicas con vinculación baja», FB). La frecuencia de aparición de la variable mora es distinta en los diferentes grupos en los tres momentos temporales, siendo más alta entre los Autónomos con baja vinculación y la más baja en Físicas con vinculación muy fuerte. En general, la morosidad disminuye con el grado de vinculación.

Las variables explicativas disponibles pueden clasificarse en tres grupos o bloques: 1) variables categóricas que miden el uso de productos y servicios por el cliente tanto en el momento de predicción

de la mora como el cambio experimentado entre el momento que se explica y el momento observado anterior; 2) variables cuantitativas que miden recursos disponibles: cantidades en cuentas corrientes, fondos, etc., así como el cambio de recursos experimentado respecto al momento observado anterior; y 3) variables de red que miden la relación de ese cliente con otros clientes morosos, así como las correspondientes variables de cambio. En este tercer bloque de variables, se consideran 12 variables: 1) proporción de vecinos morosos a 1 Paso (una variable para Autónomos, otra para Empresas y otra para Físicas); 2) cambio en la proporción de Autónomos morosos a 1 Paso (tres variables como antes); 3) como en 1, pero vecinos a dos pasos; y (4) como en 2, pero vecinos a dos pasos.

Una vez definidas las variables explicativas, se introducen en el modelo de regresión logística y se lleva a cabo un procedimiento estadístico automático e iterativo de eliminación «hacia atrás» (*backward*) de variables. Este procedimiento automático se ha combinado con algunas reglas diseñadas *ad hoc* para estos modelos, como por ejemplo la eliminación de variables con valores diferentes de 0 en menos del 1 por 100 de las observaciones de un modelo.

Los resultados obtenidos en las dos primeras regresiones logísticas, es decir a los modelos explicativos, se pueden resumir en tres puntos fundamentales:

1. La variable «Mora en el período anterior» entra en todos los modelos de tal manera que indica que los clientes en mora hace seis meses tienen una probabilidad muy alta de continuar en mora seis meses después.
2. Las relaciones en la red con morosos hacen aumentar mucho la probabilidad de mora. Existe una relación positiva entre la variable mora en el período a explicar y las variables «Proporción de Autónomos Morosos a 2 Pasos» y «Proporción de Empresas Morosas a 2 Pasos». Un resultado similar se observa para las variables de cambio asociadas a estas variables («Cambio en la Proporción de Autónomos Morosos a 2 Pasos» y «Cambio en la Proporción de Empresas Morosas a 2 Pasos»).
3. Hay un pequeño grupo de variables que en muchos de los modelos, si bien su importancia relativa con respecto a las variables mencionadas en los dos puntos anteriores es muy inferior.

Estos resultados sugieren que a corto plazo es posible prever la mora con muy pequeño error. De hecho, con estas variables explicativas un modelo logístico es capaz de prever la mora a corto plazo con un error del orden de uno por mil para los falsos positivos (se prevé que el cliente entra en mora cuando no lo hace) y del uno por cien para los falsos negativos (se prevé que el cliente no entra en mora cuando sí lo hace). Además, los resultados obtenidos demuestran la importancia que tienen las variables de red para la explicación de la mora. Si eliminamos dichas variables, los modelos explicarían la mora mucho peor.

Sin embargo, los resultados obtenidos en la tercera regresión logística, es decir para el modelo predictivo a seis meses, son notablemente inferiores. Los errores de predicción obtenidos para la mora en el momento M3 son mucho más altos como consecuencia de que prevemos con información sobre la situación de los clientes hace seis meses, y no uno o dos meses antes. Es decir, que las variables importantes en los casos explicativos no son capaces de prever con precisión la aparición de mora en un horizonte de seis meses. Esto sugiere que un modelo con información dinámica de la evolución de las variables detectadas como clave en los pocos meses previos a la entrada en mora será capaz de prever la entrada de un cliente en mora en uno o dos meses con un pequeño error.

## V. CONCLUSIONES

Los bancos, cajas de ahorros y otras instituciones financieras pueden mejorar su situación diseñando mecanismos para recoger y analizar la enorme cantidad de información que genera la actividad económica de sus clientes y utilizarla para adaptar más sus políticas comerciales a las necesidades de sus clientes. Por ejemplo, el análisis detallado de distintas series de ingresos y gastos en la cuenta de cada cliente puede anticipar cambios que indican un aumento de su probabilidad de abandono. Por otro lado, esta información permitiría anticiparse a las necesidades de los clientes y proponerles estrategias para mejorar su comportamiento financiero. Además, esta información puede enriquecerse con otros datos disponibles sobre los clientes en las redes sociales y otros sistemas públicos de captación de datos, mejorando la segmentación de los clientes y permitiendo mejores predicciones sobre su actividad. Un uso inteligente de toda esta información



puede aumentar la lealtad de los clientes con su institución, mejorar la imagen pública del banco y situarlo en una posición más sólida ante los retos futuros derivados de la entrada en el sector financiero de empresas líderes en la recogida y manejo de información.

La información detallada sobre sus clientes puede además reducir sus costes, al disminuir el fraude y la morosidad, y conducir a mejores predicciones que disminuirán los costes asociados al riesgo.

Por otro lado, los grandes bancos disponen al agregar la evolución de sus clientes, preservando la confidencialidad de los datos individuales, de una información muy valiosa para prever el ciclo económico y anticipar problemas en sectores concretos. La experiencia en áreas indica que esta información, convenientemente utilizada, puede generar nuevo valor económico.

#### BIBLIOGRAFÍA

- ABDALLAH, A., MAAROF, M. y ZAINAL, A. (2016). Fraud detection system: A survey. *Journal of Network and Computer Applications*, 68, pp. 90-113.
- BARTOV, E., FAUREL, L. y MOHANRAM, P. S. (2018). Can Twitter help predict firm-level earnings and stock returns? *The Accounting Review*, 93, pp. 25-57.
- BENOIT, D. F. y VAN DEN POEL, D. (2012). Improving customer retention in financial services using kinship network information. *Expert System with Applications*, 39, pp.11435-11442.
- BISHOP, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- BLONDEL, V. D., GUILLAUME, J.-L., LAMBIOTTE, R. y LEFEBVRE, E. (2008). Fast unfolding of communities in large networks. *Journal of Statistical Mechanics: Theory and Experiment*, (10), P10008.
- BOLTON, R. y HAND, D. J. (2002). Statistical fraud detection: A review. *Statistical Science*, 17, pp. 235-249.
- BRANDES, U., DELLING, D., GAERTLER, M., GORKE, R., HOEFER, M., NIKOLOSKI, Z. y WAGNER, D. (2008). On Modularity Clustering. *IEEE Transactions on Knowledge and Data Engineering*, 20, pp. 172-188.
- BUREZ, J. y VAN DEN POEL, D. (2008). Separating financial from commercial customer churn. *Expert System with Applications*, 35, pp. 497-514.
- CHEN, H., DE P., HU Y. J., y HWANG, B.-H. (2014). Wisdom of crowds: The value of stock opinions transmitted through social media. *Review of Financial Studies*, 27, pp. 1367-1403.
- CLAUSET, A., NEWMAN, M. E. J. y MOORE, C. (2004). *Finding community structure in very large networks*. <http://www.arxiv.org/abs/cond-mat/0408187>
- DE BOCK, K. y VAN DEN POEL, D. (2011). An empirical evaluation of rotation-based ensemble classifiers for customer churn prediction. *Expert Systems with Application*, 38, pp. 12293-12301.
- DORRONSORO, J. R., GINEL, F., SÁNCHEZ, C. y CRUZ, C. S. (1997). Neural fraud detection in credit card operations. *IEEE Transactions on Neural Networks*, 8, pp. 827-834.
- EINAV, L. y LEVIN, J. (2014). The data revolution and economic analysis. *Innovation Policy and the Economy*, 14, pp. 1-24.
- EUROPEAN CENTRAL BANK (2018). *Fifth Report on card fraud*. [https://www.ecb.europa.eu/pub/cardfraud/html/ecb\\_cardfraudreport201809.en.html](https://www.ecb.europa.eu/pub/cardfraud/html/ecb_cardfraudreport201809.en.html)
- FANG, B. y ZHANG, P. (2016). Big data in finance. En *Big Data Concepts, Theories, and Applications*. Springer, pp. 391-412.
- GALEANO, P. y PEÑA, D. (2019). Statistics, Big Data and Data Science (with discussion). *TEST*, 28, pp. 289-368.
- GIANNONE, D., REICHLIN, L. y SMALL, D. (2008). Nowcasting: The real-time informational content of macroeconomic data. *Journal of Monetary Economics*, 55, pp. 665-676.
- GRANOVETTER, M. S. (1973). The strength of weak ties. *The American Journal of Sociology*, 78, pp. 1360-1380.
- HASTIE, T., TIBSHIRANI, R. y FRIEDMAN, J. H. (2009). *The Elements of Statistical Learning Data* (2nd edition). Springer.
- KAHNEMAN, D. (2012). *Pensar rápido, pensar despacio*. Debate.
- KAPETANIOS, G. y PAPAILLIAS, F. (2018). Big Data & Macroeconomic Nowcasting: Methodological review. *ESCoE Discussion paper*, 2018-12.
- KOU, Y., LU, C.-T., SIRWONGWATTANA, S. y HUANG, Y.-P. (2004). Survey of fraud detection techniques. En *IEEE International Conference on Networking, Sensing and Control*, 2004. IEEE, pp. 749-754.
- MARUATONA, O., VAMPLEW, P. y DAZELEY, R. (2012). Prudent fraud detection in Internet banking. *2012 Third Cybercrime and Trustworthy Computing Workshop*. IEEE, pp. 60-65.
- MASTHOFF, J. y GATT, A. (2006). In pursuit of satisfaction and the prevention of embarrassment: affective state in group recommender systems. *User Modelling and User-Adapted Interaction*, 16, 281-319.
- MAYER-SCHÖNBERGER, V. y CUKIER, K. (2013). *Big data: A revolution that will transform how we live, work, and think*. Houghton Mifflin Harcourt.



- PARADIS, L. y HAN, Q. (2007). A survey of fault management in wireless sensor networks. *Journal of Network and Systems Management*, 15, pp. 171-190.
- PEDREGOSA, F. *et al.* (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, pp. 2825-2830.
- PEÑA, D. (2014). Big Data y Estadística: ¿Tendencia o cambio? *Boletín de Estadística e Investigación Operativa*, 30, pp. 313-324.
- (2015) Big Data, Ciencia y Estadística. *Revista de Ciencia y Humanidades*, 14, pp. 97-106. Fundación Ramón Areces.
- PHUA, C., LEE, V., SMITH, K. y GAYLER, R. (2010). A comprehensive survey of data mining-based fraud detection research. arXiv preprint arXiv:1009.6119.
- PONS, P. y LATAPY, M. (2005). *Computing communities in large networks using random walks*. <http://arxiv.org/abs/physics/0512106>
- QUIJANO-SÁNCHEZ, L. y LIBERATORE, F. (2017). The BIG CHASE: A decision support system for client acquisition applied to financial networks. *Decision Support Systems*, 98, pp. 49-58.
- SETH, T. y CHAUDHARY, V. (2015). Big Data in Finance. En Li, K.-C., JIAANG, H., YANG, L. T., CUZZOCREA, A. (eds.), *Big Data: Algorithms, Analytics, and Applications*, 1 ed., Chapter 17, CRC Big Data Series, p. 29. Chapman&Hall.
- UGARTE, M. D., MILITINO, A. F. y ARNHOLT, A. T. (2015). *Probability and Statistics with R*. Chapman and Hall/CRC.

## Resumen

La irrupción digital y el avance tecnológico han supuesto una revolución en la sociedad y en la organización empresarial. El sector financiero no es ajeno a estos cambios. En este artículo ilustramos el impacto que el uso de la ciencia de datos y la inteligencia artificial han tenido en la transformación del sistema financiero, en los procesos internos de las entidades y en el servicio al cliente, analizando el marco técnico, competitivo y regulatorio que delimita la frontera del *big data* y que serán clave para el impacto que tendrá en la industria de servicios financieros.

**Palabras clave:** banca, finanzas, inteligencia artificial, big data, ciencia de datos, transformación digital.

## Abstract

Digital transformation and technology developments have led to a revolution in society and business organizations that has also reached financial services. In this article we show the impact that the use of data science and artificial intelligence have had in the transformation of the financial system, firms' internal processes and customer service, assessing the technical, competitive and regulatory framework that shape the current frontiers of big data and will be key in how it will shape the new structure in the financial services industry.

**Keywords:** banks, finance, artificial intelligence, big data, data science, digital transformation.

**JEL classification:** C55, C81, C83, G21, L51, L52.

# FRONTERAS DEL *BIG DATA* PARA EL ANÁLISIS ECONÓMICO Y FINANCIERO EN BANCA

Jesús LOZANO

Tomasa RODRIGO

Jorge SICILIA (\*)

BBVA

## I. INTRODUCCIÓN

EL documento se articula en torno a dos grandes líneas: una teórica centrada en la gestión del dato, las oportunidades y los riesgos que brinda al sector financiero; y otra empírica centrada en el análisis y las aplicaciones desarrolladas en BBVA alrededor del uso del *big data*. Comenzamos destacando los cambios en el marco financiero con la transformación digital y el avance tecnológico (sección segunda). En la tercera sección abordamos los tres pilares para la aplicación de técnicas avanzadas de análisis de datos en el sector financiero: la ética, la regulación y la gobernanza; pilares sobre los que se debe generar la confianza de los usuarios, indispensable para la adopción de nuevos servicios. En la sección cuarta, presentamos las implicaciones que este nuevo marco tiene sobre la innovación, competencia y estabilidad de los servicios financieros. En la quinta sección analizamos las aplicaciones generadas para entender el entorno económico y conocer mejor al usuario, mostrando algunos ejemplos particulares de análisis y de servicios desarrollados en BBVA; y explicamos cómo es imprescindible una coordinación entre el sector público y privado para aprovechar el potencial del *big data* (sección sexta). En la sección séptima planteamos algunas ideas de cómo podría

evolucionar el sector financiero con la aplicación de estas nuevas técnicas y, finalmente, concluimos.

## II. NUEVO MARCO FINANCIERO

La productividad mundial se está desacelerando desde la década del 2000; lo que contrasta con la revolución generada por la irrupción de las tecnologías digitales, omnipresente en muchos ámbitos de actividad. En un debate todavía sin cerrar, hay autores que defienden que esta tecnología no tendrá un gran impacto en la productividad (Gordon, 2016), y otros que defienden que lo tendrá, pero que hay que esperar para que lo termine haciendo (Brynjolfsson, Rock y Syverson, 2017; Crafts, 2018). El argumento central de estos últimos es que los efectos de la inteligencia artificial –IA– y el *big data*, uno de los subcampos más rompedores de esta tecnología, se van a ver con un rezago, dado que dicha tecnología es, como la electricidad o las tecnologías de la información y la comunicación, una tecnología de objetivos amplios –*general purpose technology*– (Bresnahan y Trajtenberg, 1996); y, como estas, su impacto en la productividad tardará en llegar porque su difusión es lenta y sus efectos plenos necesitan de la generación e implementación de innovaciones complementarias,

que incluyen cambios en la organización empresarial, la sociedad y la generación de nuevas habilidades individuales que ya se están acumulando en forma de capital intangible.

Esta paradoja no se da a nivel de empresa, donde hay evidencia de aumentos de la productividad en un subconjunto de empresas frontera que usan activamente la tecnología digital; pero parece que no se difunde a un conjunto más amplio del tejido productivo (OCDE, 2015).

En el sistema financiero la semilla de los cambios ya se está viviendo con fuerza en muchas empresas tanto *fintech* como *bigtech* (Phillippon 2017; Comisión Europea, 2018) hasta el punto de que se habla de altos riesgos de disrupción por el fenómeno *bigtech* (De la Mano *et al.*, 2018; Vives, 2019).

Las innovaciones en el sector financiero –aquello nuevo que «reduce costes, riesgos o proporciona un producto o servicio que satisface mejor las demandas de los usuarios»– han dirigido el desempeño del sector en las últimas décadas, y, aunque también han sido muy costosas debido a las crisis que ha protagonizado, la evidencia muestra que han sido beneficiosas en términos netos (Beck *et al.*, 2016; OCDE, 2017; Frame, Wall y Lawrence, 2018). La siguiente ola se basará en la inteligencia artificial. ¿Cómo será esta innovación? Los datos no están cambiando la función del sistema financiero, que sigue siendo la que ya apuntó Merton (1992): facilitar la asignación de recursos económicos en un entorno incierto; lo que quiere decir dar cobertura al sistema de pagos, facilitar la transferencia de recursos entre ahorradores a

corto plazo y prestatarios a largo plazo, gestionar la monitorización del riesgo de crédito y proporcionar asesoramiento financiero. Estas son funciones con un extenso y dinámico uso de datos, la principal materia prima del cambio tecnológico actual. A través de ellos el sector está cambiando como consecuencia de las nuevas opciones de personalización masiva y la posibilidad de crear mercados individuales para cada usuario por parte de múltiples proveedores. No cambian las funciones, cambian los actores y cómo se declinan todos estos servicios.

La experiencia de otras industrias más avanzadas en el uso del dato muestra que esta tecnología se ha dirigido menos a diferenciar precios –aunque sí a reducirlos– y más a proporcionar a los usuarios información más apropiada, y relevante para sus intereses. Es decir, se ha concentrado en ser más preciso en los objetivos y las recomendaciones al cliente. También permite una mejor verificación de la información; y crear una reputación digital (Goldfarb y Tucker, 2017), algo clave en el negocio financiero. Ya hay experiencias muy desarrolladas en el mundo *fintech* que, solo con el uso del dato masivo, han generado índices crediticios usando hábitos de uso y compra de Internet, membresías o uso de redes sociales. Este tipo de aplicaciones son centrales para el sistema financiero porque pueden ayudar a mejorar el análisis de riesgos del potencial deudor de acuerdo a sus características, los sectores donde se desempeña (entorno económico y geográfico), sus hábitos de interacción, etcétera.

El sector está entrando de lleno en usar masivamente el dato para

gestionar el riesgo, optimizar procesos internos, ayudar en el cumplimiento de la regulación y crear nuevas funciones de asesoramiento personalizado en las decisiones de ahorro, endeudamiento y gestión de pagos. Este fenómeno se generalizará por la demanda de los clientes de inmediatez y personalización de los servicios y por la mayor consciencia de todas las empresas del valor y utilidad del creciente volumen de datos que usan y se generan en su interacción con los clientes.

Los datos serán tan necesarios que la posibilidad de acceder o no a ellos será una importante barrera a la entrada en el mercado. De hecho, reducir esos obstáculos para fomentar la competencia es uno de los objetivos de la PSD2, revisión de la Directiva de Servicios de Pago aprobada en Europa que, entre otras cuestiones, permite a las entidades bancarias y no bancarias previamente registradas por una autoridad financiera acceder a los datos de un usuario si este lo autoriza explícitamente.

### III. PILARES DE ESTE NUEVO MARCO FINANCIERO

A pesar de las grandes oportunidades que ofrece este nuevo entorno de abundancia de datos, el uso del *big data* por las entidades financieras presenta grandes retos, ya que el dominio de estas técnicas requiere contar con datos masivos y de calidad, pero también talento humano y tecnología adecuada, además de disponer de un marco organizativo y tecnológico que garantice la seguridad y disponibilidad de la información y recursos necesarios para generar valor añadido sin crear nuevos riesgos. Adicionalmente, existen muchos

otros aspectos técnicos, competitivos y regulatorios que afectan a la capacidad de las entidades financieras de extraer valor con estas técnicas. Son todos estos cambios los que deberían permitir que esta tecnología termine generando un aumento de la productividad en el sector cuando se produzcan todas las innovaciones que se necesitan.

En esta sección abordamos tres elementos clave para revolucionar el sector y definir la frontera del *big data*: ética, regulación y gobernanza. Solo erigiendo estos pilares sólidamente las entidades podrán desarrollar soluciones de valor añadido, satisfacer a sus clientes y merecer su confianza, el pilar imprescindible sobre el que se seguirá desempeñando la provisión de servicios financieros.

## 1. Ética: uso responsable de la información

Uno de los temas de mayor actualidad en el uso del dato en cualquier sector está en las implicaciones éticas de la aplicación indiscriminada de técnicas de aprendizaje automático (Bostrom y Yudkowsky, 2014) que aumentan la capacidad de inferir información valiosa de un individuo o una población y que podría usarse en contra de sus intereses.

Este debate ético se ha intensificado últimamente (Daly *et al.*, 2019) y ha cobrado un especial protagonismo tras el escándalo de Cambridge Analytica (Rosenberg, Confessore y Cadwalladr, 2018), que mostró el potencial de la aplicación malintencionada de técnicas de análisis de datos avanzadas. Acelerado por esta preocupación, están surgiendo recomendaciones sobre el tra-

tamiento ético de los datos, especialmente en IA, que reflejan los cuatro principios básicos de la ética biomédica (Beauchamp y Childress, 1979): beneficencia, autonomía, justicia y no maleficencia. Aunque estos elementos ya se reflejan en la legislación europea, el mayor grado de automatización y sofisticación de las técnicas de análisis avanzado de datos tiene el potencial de magnificar problemas preexistentes, por lo que este debate ético debe convertirse en una oportunidad para revisar el marco regulatorio actual y los principios éticos subyacentes; y realizar los ajustes necesarios para generar confianza y seguridad al usuario y a la sociedad, posiblemente en línea con el cumplimiento de los criterios éticos y regulatorios ya aplicados (por ejemplo a técnicas menos sofisticadas con similares riesgos asociados). Se trata de garantizar el uso ético y, al tiempo, de evitar la creación de obstáculos injustificados al desarrollo de unas técnicas con un gran potencial para abordar problemas que hasta ahora parecían irresolubles y determinarán la productividad futura de empresas y países y el bienestar de los usuarios.

En cualquier caso, al no tener todas las aplicaciones del *big data* los mismos riesgos éticos, se necesitará realizar un análisis previo que identifique los potenciales riesgos asociados a los factores que han hecho posible el desarrollo del *big data* y la IA (tecnología, talento y datos), al resultado del análisis que emana de su uso, y al tipo de decisiones y acciones que sustenta cada caso.

Sin duda, uno de los aspectos con mayores implicaciones éticas son los potenciales sesgos que puedan aparecer en el proceso. El resultado de un mode-

lo de analítica avanzada nunca será mejor que los datos que se hayan utilizado en su construcción. Por ello, controlar el sesgo en los datos utilizados es primordial. Como señala el Institute of International Finance (2019), podemos distinguir tres tipos de sesgos: los inherentes a la fuente de datos, si esta no recoge toda la diversidad de la población a la que pretende representar; los de asociación, si se utilizan datos correlados con información sensible aunque esta se haya excluido del estudio inicialmente; y los de limpieza y transformación, si en estos procesos se afecta la diversidad o representatividad de los datos. Aunque los más evidentes y comentados son los sesgos en las fuentes de datos (por esto es vital la gobernanza del dato sobre la que elaboramos más adelante), no son los únicos y en la propia selección de la tecnología y del talento se pueden incorporar sesgos. Pensemos, por ejemplo, en el consumo de un algoritmo de procesamiento de lenguaje natural entrenado por el proveedor del mismo y consumido a través de un mecanismo automatizado como una *API (application programming interface)* o en la elaboración de algoritmos por parte de equipos de trabajo en que todos los miembros pertenecieran a un mismo grupo social o tuvieran un perfil exclusivamente técnico que perjudicara la consideración de aspectos no técnicos como el legal o el ético, o la detección del incorrecto diseño o funcionamiento del sistema en su interacción con usuarios pertenecientes a otros grupos sociales.

Para reducir estos sesgos es fundamental tener una clara concepción implementada en los procesos de lo que es ético y tomar medidas que identifiquen

y aborden explícitamente aquellos sesgos que no pueden eludirse simplemente ignorando una determinada categoría de información, como sucede en aquellos entornos en que un determinado grupo de personas han contado históricamente con menos oportunidades y, por tanto, otras variables inicialmente no relacionadas con la que ha originado esta discriminación –como el nivel de estudios o el lugar de residencia– tienen una alta correlación con la característica ignorada.

Si la corrección de estos sesgos se realiza correctamente, el sistema financiero resultante no solo será más ético sino también más inclusivo, pues hará posible un mejor acceso a servicios financieros de individuos pertenecientes a grupos sociales o económicos desfavorecidos.

## 2. Regulación

Además del debate ético, el cumplimiento de la normativa vigente es condición necesaria, aunque no suficiente para garantizar un correcto uso y funcionamiento de los sistemas de analítica avanzada y minimizar sus implicaciones éticas. La regulación es vital para el buen funcionamiento del sector.

Dos grandes grupos normativos impactan en el uso del *big data* en la industria financiera: la normativa horizontal, aplicable a cualquier sector de actividad, y la que regula exclusivamente la actividad financiera. Dentro de este último grupo, las normas pueden afectar a toda la actividad financiera o a actividades concretas como la concesión de préstamos o el asesoramiento financiero.

Poniendo el foco en la regulación de la Unión Europea, la apli-

cación del *big data* en cualquier sector de actividad está sometida a distintos tipos de normas: las que garantizan los derechos fundamentales de los ciudadanos, regulando, entre otros, la no discriminación o la protección de la privacidad, aspecto relevante en una disciplina en que el dato es la materia prima; las de protección al consumidor, para garantizar su seguridad, la transparencia de la información y su libertad de elección; y las normas de seguridad de los sistemas de información que establecen requisitos sobre la tecnología necesaria. En el ámbito financiero también existen normas prudenciales y conductuales, donde se incluyen requisitos específicos de protección del consumidor, de funcionamiento de los mercados financieros y de prevención de actividades ilícitas.

La combinación de estos grandes bloques regulatorios establece el marco/los límites regulatorios al desarrollo y aplicación de técnicas de analítica avanzada en el sector financiero. Destacamos las que hoy son más relevantes, con una valoración asociada:

– *Discriminación*. La no discriminación por motivos de raza, creencias políticas o religiosas, orientación sexual, etc., es básica en la normativa europea y, especialmente, en actividades financieras como acceso al crédito. Mediante el uso del *big data* se puede tener una visión más profunda de los solicitantes de crédito, reduciendo el margen de error en la concesión así como explorar alternativas para la evaluación de la solvencia de los solicitantes sin suficiente historia financiera. Sin embargo, asegurar un resultado no discriminatorio no es trivial, dado que variables como el lugar de residencia o la

ocupación pueden estar relacionadas con características como la raza o estatus social que no deberían tenerse en cuenta en el modelo (Zuiderveen, 2018).

– *Localización*. La normativa de protección de datos limita su movimiento internacional, lo que podría perjudicar el uso del *big data* en modelos que requieran datos de distintas jurisdicciones.

– *Manipulación*. La complejidad inherente a muchos modelos de analítica avanzada puede tener efectos adversos sobre individuos, servicios o mercados motivados por un deficiente análisis de riesgos, una intervención mal intencionada o, incluso, de la casualidad no controlada.

– *Remuneración*. La normativa prudencial limita la capacidad de los bancos de ofrecer remuneraciones competitivas frente a empresas tecnológicas interesadas en captar el mismo talento.

– *Responsabilidad*. Tanto en la normativa general como en la financiera es fundamental garantizar que la intervención de múltiples actores en un servicio o en la toma de una decisión o la automatización de algún proceso no impide asignar responsabilidades correctamente.

– *Riesgos*. Las normas de ciberseguridad y prudenciales se centran en la identificación y minimización de riesgos. Dentro de los riesgos a controlar en el ámbito financiero son especialmente relevantes los asociados a la concesión de crédito mientras en el ámbito operativo los asociados a la externalización de actividades están sometido a requisitos legales adicionales.

– *Transparencia*. En muchos ámbitos de actividad y recomen-



daciones es necesario demostrar que el comportamiento y decisiones del sistema han respetado las obligaciones legales aplicables. Este nivel de transparencia a ofrecer dependerá del caso de uso y los actores implicados. Así, por ejemplo, principios como el derecho a explicación de decisiones automatizadas con impacto significativo establecido por el Reglamento General de Protección de Datos (RGPD) o la responsabilidad última de la alta dirección en la gestión de riesgos establecida en las directrices de gobierno interno son especialmente relevantes para determinar el nivel de transparencia que será necesario ofrecer a un cliente, la dirección o los supervisores de una entidad, por ejemplo.

– *Uso de datos.* Para poder utilizar datos personales en un determinado modelo se debe no solo tener acceso a ellos, sino disponer de una base de legitimación para su tratamiento. El RGPD ha aumentado el control de los usuarios sobre sus datos y ha establecido derechos como la portabilidad que reducen los obstáculos a la compartición controlada de datos. Sin embargo, la falta de un estándar tecnológico que facilite la compartición intersectorial de forma similar a lo que ha establecido la PSD2 en el ámbito de los pagos es el mayor obstáculo para el acceso a los mismos. Además, en aplicación del principio de minimización del dato previsto en el RGPD, las entidades financieras solo pueden usar/acceder a ellos si es necesario para la ejecución de una actividad concreta, durante el tiempo necesario y bajo una base que lo justifique. Esto abre interrogantes sobre las normas de competencia y si esta configuración predispone a una estructura específica del sector financiero en el futuro.

La forma en que estos aspectos afectan a la utilización de técnicas de *big data* en el sector financiero depende en gran medida del caso de uso a desarrollar para cada dato. En líneas generales, el impacto de la regulación en la aplicación de modelos de analítica avanzada es mayor en las actividades financieras reguladas con impacto directo en clientes que en actividades de análisis o investigación, ya que estas generalmente usan fuentes de datos públicas o bases de datos agregadas y anonimizadas.

En el resto de los casos de uso el tratamiento de datos será más fácil en aquellos en que no se requiera acceso a la información personal identificada o el tratamiento esté justificado por obligaciones legales concretas como en el control del blanqueo de capitales (*anti money laundering*) o algo más genéricas de protección del consumidor o ciberseguridad (control del fraude). Si los casos de uso combinan otras fuentes de datos, se suman nuevos obstáculos legales basados en los principios de minimización de la información y especificidad del consentimiento.

Especialmente retadora se presenta la innovación en casos de uso como la concesión de crédito donde normativa como la Directiva de Crédito Hipotecario restringe explorar análisis alternativos que tengan en cuenta la huella digital del cliente como proponen Berg *et al.* (2018).

En lo que se refiere a la tecnología, las entidades financieras deben analizar y gestionar los riesgos asociados a sus infraestructuras tecnológicas, entre los que se encuentran los asociados a la externalización de servicios en terceros. Esto supone que en la

utilización de servicios de análisis de datos bajo demanda ofrecidos por proveedores de soluciones en la nube deben cumplirse requisitos que no aplicarían sobre soluciones tecnológicas desarrolladas y operadas internamente.

Finalmente, en el área de la transparencia es donde la variabilidad de los requisitos es mayor, pues en aquellos casos de uso con un impacto significativo sobre el cliente como la concesión de crédito (y la fijación de un precio-tipo de interés) o el asesoramiento financiero es necesario cumplir con los requisitos de explicabilidad del RGPD y, en el caso del asesoramiento, con las obligaciones de transparencia y protección establecidas en la Directiva de Mercados de Instrumentos Financieros.

Por otro lado, en aquellas actividades que requieren autorización previa por parte de la autoridad, como en el desarrollo de modelos propios de cálculo de capital, será necesario que la autoridad entienda y pueda comprobar el funcionamiento del modelo antes de su implantación.

No obstante, incluso en aquellos casos de uso en que el impacto sobre los clientes es menos relevante, como en el control de fraude o en sistemas de recomendaciones, el cliente podría exigir a la entidad explicaciones sobre el deficiente resultado de los mismos si considera su impacto como significativo o, incluso, la demostración de que estos resultados no son discriminatorios.

### 3. Gobernanza del dato

Además de la ética y la regulación, hay un tercer pilar mucho más concreto que es fundamen-

tal para el éxito de una estrategia basada en datos en cualquier organización o industria: la gobernanza de la información cuyo objetivo principal es garantizar la seguridad, exactitud, vigencia y utilización adecuada de los mismos en todas las fases del ciclo de vida del dato: desde su creación, almacenamiento, uso, análisis y posterior eliminación de la información.

Esta gobernanza cobra especial relevancia en el entorno actual en que los datos aumentan exponencialmente y son de naturaleza y características muy diversas: generados en tiempo real, heterogéneos y desestructurados. Estas particularidades hacen que la identificación y procesamiento de los datos antes de iniciar la fase de análisis ocupe en muchos casos más de las dos terceras partes del tiempo de desarrollo de un proyecto. Un buen gobierno reduce los riesgos asociados al ciclo de vida del dato, pero también permite una gestión más eficiente de la información. Para garantizar esta buena gobernanza, se requiere de la sinergia de tres elementos: tecnología, procesos y personas.

Comenzando por la tecnología, el uso de una plataforma integrada y escalable que garantice el cumplimiento de las políticas de seguridad de la información establecidas por la organización y que incluya herramientas de gestión de datos en la ingesta y almacenamiento de la información es la piedra angular de una eficaz gobernanza de la información. La velocidad a la que las empresas crean, actualizan y utilizan sus datos ha aumentado por el desarrollo de soluciones basadas en la nube que permiten manejar un mayor volumen y variedad de datos a una gran ve-

locidad garantizando condiciones de seguridad de la información previamente establecidas.

Una vez que se cuenta con la información disponible –un proceso dinámico porque la información se genera continuamente–, es crítico definir procesos y reglas a aplicar a los datos para garantizar su precisión, integridad y coherencia corrigiendo duplicidades, eliminando redundancias, arreglando inconsistencias y, sobre todo, garantizando la calidad de la información y asegurando su privacidad, confidencialidad y seguridad. Este complejo equilibrio debe venir acompañado de procesos de control y auditoría, así como de una evaluación de los niveles de sensibilidad de los datos.

Por último, los procesos de supervisión y control de calidad de los datos se deben llevar a cabo por personas y equipos multidisciplinares que puedan asegurar que el gobierno del dato está alineado con las necesidades y estrategias del negocio, con un acceso seguro a la información.

Será la interacción de todos estos factores la que defina una gobernanza de la información exitosa, y sobre ella se deberán construir las ventajas competitivas para operar en un entorno cada vez más dinámico y competitivo donde el tiempo de reacción en la ejecución de procesos (el *time to market*), juega un papel crítico. Utilizando un símil del sector petrolero, si el dato es el nuevo petróleo del siglo XXI, no es la gasolina. La gobernanza de la información será uno de los factores que ayuden a refinar el combustible necesario para echar a rodar. Es más: el dato es especial porque es un bien no rival (Varian, 2018;

Jones y Tonetti, 2019); es una gasolina que no se consume por su uso, se puede utilizar al mismo tiempo en distintos viajes o reutilizarla en otros.

#### 4. Confianza

La confianza es la piedra angular del negocio de servicios financieros. En el desarrollo de servicios innovadores basados en el uso del *big data*, como lo ha sido en el propio negocio bancario, el usuario estará dispuesto solamente a utilizarlos si percibe un beneficio claro en hacerlo y tiene confianza en su funcionamiento. Esto es posible si se demuestra que se han analizado correctamente todos los potenciales impactos y se han tomado las medidas mitigadoras oportunas. El correcto desarrollo de la ética, la regulación y la gobernanza del dato es imprescindible para generar confianza y que el sector colabore en apuntalar un crecimiento sostenible. Un exigente marco regulatorio financiero puede ayudar en la generación de confianza, pues la normativa bancaria exige a los bancos contar con códigos de conducta, sistemas de gobierno interno y control de riesgos robustos y el cumplimiento de estos requisitos está sometido a continua supervisión por las autoridades financieras competentes. Será vital ver cómo se desarrolla para otros actores.

#### IV. INNOVACIÓN, COMPETENCIA Y ESTABILIDAD FINANCIERA

La gestión del dato está alterando los procesos de creación de valor en el sistema financiero generando la aparición de nuevos servicios y nuevos actores;

y tiene el potencial de cambiar la estructura de la industria. En otros sectores se ve una tendencia hacia plataformas, donde el efecto de red es vital. En el sector financiero, la generación de masa crítica alrededor de la información va a ser un elemento de competencia crucial, en el campo de juego que fije la regulación (Vives, 2019).

Es una predicción sencilla anticipar que la evolución de la industria va a ser dinámica alrededor de la gestión de datos y del uso de la IA; así como de la interacción de los tres elementos: el ético, el regulatorio, y el de la gobernanza del dato. Y aunque cabe esperar que el valor del dato termine teniendo rendimientos decrecientes de escala en términos del valor generado (McKinsey, 2016; Varian, 2018), las empresas están todavía muy lejos de alcanzar ese punto. El dato genera ventajas competitivas tanto por su valor –exclusividad, calidad, y agregación útil del dato–, como por la capacidad analítica alrededor de él.

Por tanto, cómo se gobierne y se articule el derecho al uso de los datos es relevante para la dirección de la innovación y la transformación; tendrá impacto en cuestiones relevantes para la competencia como el tipo de información al alcance de nuevas y pequeñas empresas (Goldfarb y Tucker, 2017; Varian, 2018). Este proceso de innovación enfrentará muchos retos; entre ellos los asociados a la seguridad, la protección del consumidor; y la estabilidad financiera.

En un mundo donde hay riesgos financieros tradicionales asociados al lavado de dinero y la financiación del terrorismo; donde se puede alterar la correa

de transmisión de la política monetaria y la provisión de crédito a la economía (Gouveia *et al.*, 2017), donde puede haber un impacto en la estabilidad financiera y donde surgen retos nuevos asociados a la privacidad y a la ciberseguridad, los riesgos hay que tratarlos al tiempo que se gestionan cambios radicales en la estructura del sector.

Por un lado, porque las fronteras en la actividad financiera son más borrosas con esta tecnología digital donde el servicio financiero es «uno más» asociado generalmente a otras transacciones económicas. Las barreras de entrada están cambiando y hay un equilibrio dinámico entre los incumbentes y los entrantes; con posibilidades de múltiples equilibrios dependiendo de qué actores puedan operar y con qué criterios. No es lo mismo un nuevo entrante como las *fintech* (Philippon, 2017), que uno como las *bigtech*, que pueden tener ventajas imbatibles para ser dominantes en un mercado basado en plataformas y donde el sector financiero tradicional (más regulado y activamente supervisado) pueda ser solo una parte más del servicio. Estas empresas *bigtech*, crecientemente dominantes en el mundo digital son innovadoras, tienen una gran base de clientes, acceso posible a más clientes, muchas más interacciones con ellos (lo que multiplica la generación y acceso a los datos) y fuerte capacidad analítica; tienen personal formado y organización en torno al dato; programas de atención al cliente y fidelización (McKinsey, 2016); y pueden combinar masivamente datos no rivales que están al alcance de pocos (Goldfarb y Tucker, 2017), generando economías de alcance dominantes. Que esto sea mejor o no para el sistema

depende de muchas consideraciones de competencia y de estructura del mercado, reflexión que toca que hagan los reguladores y supervisores, para evitar las consecuencias negativas que algunos autores anticipan (De la Mano *et al.*, 2018).

Porque si las implicaciones de estabilidad financiera son ya delicadas en un sector regulado y fuertemente supervisado por las consideraciones sistémicas que tiene, no es este un sector donde se pueda crear una nueva estructura de cero que sustituya la anterior sin implicaciones sistémicas; de hecho, cambios en la estructura pueden tener implicaciones de estabilidad financiera (Fernández de Lis y Urbiola, 2019). En un mundo de plataformas donde la masa crítica precipita todo muy rápidamente, el cambio abrupto de un sistema a otro puede tener implicaciones relevantes de estabilidad financiera con potenciales costes de ajuste en las economías a través de crisis financieras. Además, no es solo que este escenario es más complejo porque la entrada de algunas de estas entidades presenta retos sistémicos por entrada directa (o indirecta como proveedor de servicios intermedios) en el mercado; sino que se puede generar una estructura de mercado basada en «un solo ganador» (*winner-takes-all*), no contestable (BaFin, 2018). Por no hablar de las implicaciones que esta alteración puede tener en la asunción de riesgos por parte de entidades financieras instaladas y rezagadas en el proceso de tecnología digital. O en la generación de sistema paralelos de pagos no gestionados por bancos centrales, o en plataformas de fondos fuera del sistema, o en la ausencia de separación entre actividades bancarias y no

bancarias (Vives, 2019). Y, sin embargo, son riesgos que hay que gestionar y decidir cómo regular porque la dinámica de cambio es imparable, y porque estas innovaciones van a ser muy beneficiosas para los usuarios de servicios financieros.

El papel de la regulación será como siempre vital en este sector para el desarrollo de estas nuevas tecnologías; y será complejo por la necesidad de encontrar un equilibrio entre permitir la innovación, garantizar la estabilidad financiera y proteger al consumidor. El reto no es menor, dado que las decisiones regulatorias que se vayan adoptando determinarán el rumbo definitivo de la industria. Quien crea que esto es una exageración, que mire lo que está pasando en China.

## V. APLICACIONES Y ANÁLISIS

Como hemos visto a lo largo del artículo, la transformación digital y el avance tecnológico han permitido recoger, almacenar y procesar cantidades masivas de datos en tiempo real procedentes de la interacción de individuos, empresas, organizaciones y gobiernos. Las redes sociales o medios de comunicación, las transacciones digitalizadas (financieras o no), las búsquedas *online* o los datos geolocalizados de teléfonos móviles son ejemplos del nuevo volumen de información generada.

Estas grandes masas de datos, en muchos casos heterogéneos y no estructurados, presentan importantes desafíos a la hora de procesarlos y analizarlos y han requerido del desarrollo de una amplia gama de herramientas y algoritmos para inferir interacciones no lineales o generar

nueva información no cuantificada previamente de manera automática.

Todo ello ha supuesto un incremento cuantitativo y cualitativo de la información disponible tanto para el análisis social, económico o financiero como para el desarrollo de servicios financieros más personalizados e innovadores o la mejora de los procesos que los soportan. Es por ello que las aplicaciones generadas a partir del uso de la ciencia de datos han aumentado exponencialmente en los últimos años, tanto cuantitativa como cualitativamente, así como el valor añadido que generan.

### 1. Visión general: aplicaciones a la banca

Las instituciones financieras utilizan cada vez más el aprendizaje automático y la IA tanto para la comprensión y anticipación de eventos del entorno económico y financiero en el que se desarrolla su actividad como para el desarrollo de aplicaciones. Estas nuevas herramientas permiten un mejor tratamiento de la información que ha contribuido a un sistema financiero más eficiente, que permite que las entidades financieras aumenten su productividad y reduzcan costes por la capacidad de tomar mejores decisiones y de forma más rápida. Esta mejora en el sistema financiero se ve reflejada en el consumidor, que tiene acceso a servicios cada vez más personalizados y una mejor experiencia que además podría reducir las asimetrías de información (IOSCO, 2017), así como, en principio, a una provisión de servicios más eficiente, una mejor gestión de riesgos y mejor cumplimiento normativo.

En línea con lo señalado por el FSB (2017), la IA y el *big data* han permitido mejorar las aplicaciones centradas en las operaciones (el *back-office*), incluida la automatización de procesos administrativos, optimización del capital, modelo de gestión de riesgos y análisis de impacto en el mercado, control del fraude y cumplimiento normativo, así como aquellas aplicaciones centradas en el cliente (el *front-office*), incluyendo *marketing* digital, asesoramiento o *chatbots*.

La incorporación de los datos de clientes a gran escala a los nuevos algoritmos permite evaluar mejor la calidad crediticia y, por tanto, determinar mejor el precio de los préstamos. El análisis de nuevos volúmenes de datos también ha permitido la evaluación de factores cualitativos tales como el comportamiento de consumo y voluntad de pago (Berg *et al.*, 2019). La incorporación de datos adicionales sobre estas medidas supone una mayor y más rápida segmentación de la calidad de los prestatarios, y, en última instancia, conduce a una decisión de crédito más eficaz (Lessmann *et al.*, 2015). Así, el uso de algoritmos de aprendizaje automático en el análisis de solvencia puede ayudar a mejorar el acceso al crédito permitiendo a las entidades tomar decisiones que antes habrían sido imposibles, como en el caso de clientes sin un historial crediticio.

Además, la IA y el aprendizaje automático pueden utilizarse para anticipar y detectar fraudes, transacciones sospechosas, incumplimientos y riesgo de ciberataques, lo que podría resultar en una mejor gestión del riesgo (Aziz y Dowling, 2018). Las nuevas fuentes de información



también han permitido relacionar datos que previamente se trataban como independientes, generando una imagen integral de las interconexiones del sistema financiero y convirtiéndose en una importante red de análisis para estudiar la propagación de choques y efectos contagio.

En el asesoramiento, el uso de la IA ha permitido mejorar el servicio y la asistencia al cliente gracias a una mejor capacitación y uso eficiente de recursos y mediante la priorización de conversaciones en función de la urgencia/relevancia de las mismas, así como el cierre automático de conversaciones sin punto de acción pendiente para liberar tiempo hacia otras acciones que generen un mayor valor al cliente. Otro avance significativo en este campo ha sido la creación de *chatbots* o asistentes virtuales para ayudar a los clientes a tramitar o resolver problemas de forma automática y sin la intervención humana. Estos programas automatizados utilizan procesamiento de lenguaje natural (PLN) para interactuar con los clientes mediante texto o voz, así como algoritmos de aprendizaje automático que les permiten evolucionar con su experiencia. Muchos de ellos se encuentran aún en fase experimental y/o se usan para interacciones sencillas (proporcionar información del saldo, alertas a los clientes o responder preguntas sencillas y en algunos casos solo en usos internos de la entidad financiera), pero a medida que se generalice su uso aumentarán sus funcionalidades y su grado de sofisticación.

Los algoritmos de aprendizaje automático también pueden mejorar la experiencia de cliente mediante el análisis de sus

datos, detectando y mostrándole pautas de gasto ocultas, oportunidades de ahorro y patrones irregulares en sus cuentas, ofreciéndole soluciones que mejoren su salud financiera.

## 2. Visión particular: aplicaciones en BBVA

Tras dar una visión general del sector, en este apartado detallamos algunos de los trabajos realizados por BBVA para ilustrar la utilidad del *big data* dentro del campo social, económico y financiero. La aplicación de técnicas de analítica avanzada permiten: i) entender mejor el entorno en el que se desarrolla el negocio mediante el análisis de dinámicas sociales o tendencias geopolíticas y sus interconexiones con la economía; ii) generar nuevos indicadores en alta frecuencia que complementan las cifras publicadas por los institutos oficiales de estadística para predecir el ciclo económico; iii) ajustar nuestra estrategia y oferta comercial a las condiciones económicas; iv) ajustar nuestra oferta de servicio a clientes en base al análisis de datos, ofreciéndoles información para tomar mejores decisiones; y v) mejorar la eficiencia y el control de nuestros procesos.

Para ello, utilizamos un conjunto amplio de información que comentamos a continuación.

### *Análisis geopolítico, social y económico para entender el contexto del sector financiero*

El análisis social y geoestratégico desempeña un papel crucial para entender un mundo cada vez más interconectado y se ha convertido en un elemento fundamental para comprender el entorno económico. Para en-

tender la evolución y percepción de estos eventos, la información procedente de redes sociales (Twitter) y medios de comunicación a escala mundial –GDELT (Leetaru y Schrodtt, 2013)– es un activo clave para tener respuestas rápidas a eventos de interés dada su alta frecuencia, así como para comprender la percepción social de los mismos, puesto que recogen la opinión generada por la sociedad, actores particulares, empresas e instituciones. Para ello, usamos técnicas de procesamiento de lenguaje natural que permiten transformar el texto en vectores cuantificables, posibilitando el análisis e interrelaciones de las palabras, identificando de qué se habla en ese texto y cómo se habla gracias al análisis de sentimiento, lo que nos ayuda a clasificar su tono en función de la connotación emocional (positiva o negativa) de las palabras que le acompañan.

De esta forma, se pueden cuantificar tendencias sociales de las cuales previamente solo teníamos un conocimiento cualitativo, como la evolución de conflictos o protestas en el mundo, estudiando su potencial impacto económico en un país o región. Estas tendencias se pueden monitorizar, además, en alta frecuencia y de manera automatizada para conocer su evolución en tiempo real, ayudando a detectar rápidamente cambios de comportamiento en todo el mundo; convirtiéndose en una importante herramienta de alerta temprana, especialmente en el cambiante panorama geopolítico actual donde la naturaleza de la inestabilidad social y la forma en la que esta se propaga se han transformado, trascendiendo fronteras y sectores (BBVA Research, 2015).




Los datos que genera la interacción social también nos ha permitido estudiar temas económicos de gran calado como el estancamiento del comercio mundial y el retroceso de la globalización, especialmente relevantes para explicar las tendencias tras la crisis de 2008. El sentimiento de la información relacionada con el comercio en los medios de comunicación refleja cómo la sociedad, instituciones y gobiernos se posicionan sobre este tema y luego toman decisiones. Un ejemplo: monitorizando los temas comentados cada segundo en la prensa, recogemos todas aquellas noticias que hablan sobre comercio para medir la evolución temporal del apoyo al comercio global «material» y «verbal» en todo el mundo (Ortiz y Rodrigo, 2018). Los resultados (gráfico 1) muestran que si bien la «cooperación material» para el comercio internacional ya estaba disminuyendo desde principios del siglo XXI (después del gran apoyo de los años setenta y ochenta), el «apoyo verbal» se mantuvo hasta que estalló la crisis financiera. Una vez que los efectos reales de la crisis se hicieron evidentes, el índice de apoyo «verbal» colapsó repentinamente convergiendo al índice de cooperación material.

Estos resultados, en línea con indicadores publicados por el *World Trade Alert* en frecuencia anual, corroboran lo sucedido; pero con la ventaja de que se adelantan significativamente a las estadísticas tradicionales, la mayoría de ellas anuales. Además, la alta granularidad de la información permite analizar este fenómeno desde múltiples perspectivas, como conocer las interrelaciones entre países en función de la coocurrencia de estos factores en las noticias. Así por ejemplo, podemos identificar

cómo afectaría a los países una escalada de la tensión comercial y el mecanismo de transmisión de un choque comercial a través del análisis de redes. El gráfico 2 muestra la red de países en noticias relacionadas con comer-

cio en 2018 donde el grosor de las aristas refleja la frecuencia con la que cada par de países se mencionan juntos y el tamaño de los nodos muestra el grado de interconexión del país con el resto de la red. Los grupos de

**GRÁFICO 1**  
**INDICADORES DE APOYO AL COMERCIO VERBAL Y MATERIAL CON**  
**BIG DATA**



Fuente: BBVA Research y The GDELT Project ([www.gdelt.org](http://www.gdelt.org)).

**GRÁFICO 2**  
**RED DE PAÍSES EN NOTICIAS RELACIONADAS CON LA GUERRA**  
**COMERCIAL EN 2018**



Fuente: BBVA Research y The GDELT Project ([www.gdelt.org](http://www.gdelt.org)).

países o clústeres encontrados capturan el corredor comercial potencial, ofreciendo información alternativa para realizar un análisis oportuno ante la rápida escalada comercial que vivimos


de los últimos años y estimar su impacto económico.

Por otro lado, las transacciones financieras generan volúmenes masivos de datos en tiempo real

y se han convertido en una prometedora fuente de información para la medición de la actividad económica. La economía de la información requiere el uso de nuevas tecnologías y fuentes de datos para mejorar los enfoques existentes y métodos tradicionales de recopilación de datos, como encuestas (Ehrlich *et al.*, 2019). Indagando en el valor analítico que encierran los datos generados por el uso de servicios financieros electrónicos, se puede estudiar el comportamiento agregado de los consumidores gracias a la información agregada y anonimizada de los pagos con tarjeta de los clientes de BBVA en terminales punto de venta españoles (Bodas *et al.*, 2017), ofreciendo un novedoso método alternativo para medir la evolución empresarial del sector del comercio minorista (ICM-BBVA). Este índice, medido tradicionalmente por institutos nacionales de estadística (el INE en España), se basa en información de encuestas realizadas con una muestra limitada de comercios. El indicador ICM-BBVA replica la estructura y evolución del índice publicado mensualmente por el Instituto Nacional de Estadística (ICM-INE) (gráfico 3), no solo a nivel nacional, sino también por comunidades autónomas y modos de distribución, la máxima desagregación disponible por el INE.

¿Qué ventajas ofrece el indicador generado con *big data* frente al método clásico de estimación de un instituto de estadística? En primer lugar el coste de obtener cada observación adicional. En el indicador de *big data*, completamente digitalizado y automatizado, el coste de la observación marginal es cercano a cero, lo que permite una ganancia obvia en comparación con la realización

GRÁFICO 3  
ÍNDICE DE COMERCIO AL POR MENOR: BBVA VS INE (DATOS ESTANDARIZADOS EN VARIACIONES MENSUALES)



Fuente: BBVA.

GRÁFICO 4  
ÍNDICE BBVA DE COMERCIO AL POR MENOR: DATOS PROVINCIALES (DATOS PRIMERA MITAD 2019 EN VARIACIONES INTERANUALES)



Fuente: BBVA.

Cambiando el foco a la información publicada en la web, el análisis de la narrativa de los bancos centrales en sus comunicados de prensa y actas de política monetaria ayuda a entender sus estrategias de comunicación, y a anticipar sus decisiones. En estos documentos, disponibles *online*, los bancos centrales comentan la situación económica e intenciones de política actuales y dan señales del camino esperado sobre futuras decisiones de política monetaria. El análisis de estos documentos siempre ha sido una importante herramienta para comprender las decisiones de política monetaria y la estrategia de comunicación de bancos centrales; pero ahora se pueden explotar de forma diferente.


REVISTA DE ECONOMÍA ESPAÑOLA, N.º 162, 2019. ISSN: 0210-9107. «LA GESTIÓN DE LA INFORMACIÓN EN BANCA: DE LAS FINANZAS DEL COMPORTAMIENTO A LA INTELIGENCIA ARTIFICIAL»

**GRÁFICO 5**  
**TEMAS MÁS FRECUENTES COMENTADOS EN LOS INFORMES DEL BCE,**  
**FED Y CBRT**



Fuente: BBVA Research.

**GRÁFICO 6**  
**POLÍTICA MONETARIA EN EL NORTE (BCE) VS PAÍSES EMERGENTES**  
**(TURQUÍA): COMPLEJIDAD E INTERCONEXIÓN EN REDES**



Fuente: BBVA Research



y cómo interactúan en el tiempo. A modo ilustrativo de los resultados de este análisis, en el gráfico 5 mostramos las palabras más comentadas por el Banco Central Europeo (BCE), la Reserva Federal (FED) y el Banco Central de Turquía (CBRT) (Ortiz y Rodrigo, 2017) y la interconexión y evolución de las temáticas identificadas en el tiempo para el BCE y el CBRT (gráfico 6).

Desde la óptica financiera, los informes trimestrales y anuales presentados por las compañías estadounidenses a la Comisión de Bolsa y Valores (SEC) también están disponibles digitalmente y encierran un gran valor analítico, puesto que permiten analizar la evolución económica, riesgos, vulnerabilidades e incertidumbres de las empresas cotizadas, por sectores de actividad y a nivel nacional. En otro trabajo, analizamos 21 millones de informes corporativos desde 1995 y utilizamos el modelado de temas para conocer qué preocupa al tejido industrial, cómo se agrupan e interrelacionan estos temas y cuál es la percepción en torno a ellos, así como indagar, una vez definida temática de interés, en el análisis de redes neuronales y las relaciones no lineales entre palabras.

Este estudio (Bolívar *et al.*, 2019) muestra que la narrativa de los informes replica la evolución de la actividad, a nivel nacional y por sector de actividad, pero además ofrece una visión más detallada para un análisis pormenorizado del negocio, oportunidades y riesgos asociados al mismo, siendo de gran utilidad para adaptar la oferta de servicios financieros a las necesidades de cada empresa.

Finalmente, por cerrar el círculo, se puede analizar con estas

técnicas las nuevas tendencias que afectan al sector financiero. El uso de la información ha sido siempre un elemento esencial en la industria financiera, caracterizada por ser un espacio altamente competitivo y estar a la vanguardia de la innovación. La disponibilidad de nuevos conjuntos de datos ha transformado la industria, donde han aparecido las *fintech*, empresas que utilizan la tecnología para ofrecer servicios financieros innovadores, transformando significativamente la industria financiera.

Empezando por la comprensión del nuevo entorno financiero con la irrupción del fenómeno *fintech*, la evidencia empírica de la información de los medios de comunicación y las redes sociales nos ayudan a comprender la nueva dinámica del sector financiero, donde la rápida evolución del cambio tecnológico hace que la información en tiempo real sea un activo muy valioso. El análisis de esta información ayuda a las

entidades a identificar áreas que requieren su atención y revela el auge de las *fintech*, que están ganando cada vez más fuerza en el debate, con una percepción social más positiva que la del sistema financiero tradicional (gráfico 7) (Ayranci *et al.*, 2019). Muestra de ello es que las temáticas asociadas con *fintech* se extienden a otros ámbitos más allá del sistema financiero como la inteligencia artificial, el internet de las cosas o el *big data* (véase gráfico 8).


#### *Nuevas herramientas para mejorar nuestros servicios*

Cambiando el foco al negocio, en este apartado mostramos cómo BBVA ha abordado este proceso de transformación digital y uso de la información como elemento fundamental en la generación de valor para la compañía, detallando algunos de los trabajos realizados en esta área.

La apuesta diferencial de transformación basada en datos de BBVA persigue la generación

GRÁFICO 7

**TONO EN MEDIOS SOBRE FINTECH Y FINANZAS 2015-2018**  
(MEDIA MÓVIL 30 DÍAS. RATIO SOBRE EL TOTAL DE NOTICIAS)



Fuente: BBVA Research y The GDELT Project ([www.gdelt.org](http://www.gdelt.org)).

GRÁFICO 8

**TEMAS MÁS FRECUENTEMENTE RELACIONADOS CON FINTECH Y FINANZAS EN LOS MEDIOS DE COMUNICACIÓN EN 2018**



Fuente: BBVA Research y The GDELT Project ([www.gdelt.org](http://www.gdelt.org)).

de capacidades que aseguren un uso óptimo y eficiente de los datos gracias a la combinación de un gobierno adecuado de la información para asegurar que los datos están bien definidos, tienen calidad, son trazables y están disponibles; una tecnología que sustente y permita el procesamiento eficiente y seguro de dichos datos; y, por último, un talento y unas capacidades de ciencia de datos que permitan a través de la analítica avanzada y la IA desarrollar aplicaciones y casos de uso que aporten valor al cliente, desarrollos actualmente centrados en cuatro grandes líneas de trabajo: automatización de procesos para mejorar métricas internas de eficiencia, personalización de la oferta (que puede ser por precio, producto, experiencia de usuario o asesoramiento), semiautomatización

o interacción humano-máquina como complemento enriquecedor de la experiencia del asesor y el uso de la IA como protección frente a eventos negativos (prevención del fraude, ciberseguridad y análisis de riesgos).

Para hacer frente a estos retos, BBVA sigue dos estrategias complementarias: por un lado ha establecido una factoría de IA, un centro global de desarrollo para la creación de capacidades de IA tanto para sus soluciones a clientes (particulares y empresas) como para la optimización de los procesos internos basado en un equipo multidisciplinar integrado por científicos de datos, ingenieros y analistas de negocio. Se ha implementado además un modelo de recualificación y reclutamiento de analistas avanzados distribuidos en once disciplinas,

con foco en la ejecución de casos de uso identificados de abajo hacia arriba desde las unidades de negocio.

La combinación de todo ello ha permitido acelerar la transformación del grupo y se ha materializado en el desarrollo de aplicaciones diferenciadoras con el objetivo de ayudar al cliente a tomar mejores decisiones y también para mejorar los procesos internos. Seleccionamos aquí unos pocos de los procesos en marcha para visualizar algunos de los cambios que se están produciendo.

Comenzando por los procesos internos, la mayor eficacia en el procesamiento de la información permite conocer mejor la evolución de nuestro negocio, ayudando a identificar desequilibrios, predecir o identificar patrones y anticipar problemas. Un ejemplo ilustrativo es la aplicación del aprendizaje automático para aumentar la precisión en la detección de fraude, una práctica especialmente relevante en el negocio bancario. El gran número de alertas que generan los sistemas actuales dificultan la predicción de fraude y pueden afectar a la experiencia de pago de los clientes. Se estima que solo uno de cada cinco alertas de fraude lo son en realidad y aproximadamente uno de cada seis clientes ha tenido una transacción válida rechazada en el último año. Como solución, BBVA en colaboración con el Massachusetts Institute of Technology demostró que la aplicación del aprendizaje automático a datos históricos de transacciones con tarjeta podrían reducir significativamente los falsos positivos y mejorar las métricas de negocio (Wedge et al., 2019).



Por otro lado, se ha demostrado que las políticas de precios desleales generan percepciones muy negativas en los clientes y pueden provocar pérdidas a largo plazo. Así, a pesar de que los modelos de precios dinámicos ayudan a las empresas a maximizar los ingresos, es imprescindible tener en cuenta la equidad y la igualdad para evitar diferencias de precio injustas entre grupos de clientes. BBVA ha trabajado con técnicas de aprendizaje reforzado para conseguir este equilibrio entre ingresos y equidad, optimizando ingresos por los servicios que presta a la vez que considera la equidad como parte del aprendizaje por su efecto a medio/largo plazo (Maestre *et al.*, 2019). Los resultados muestran una mejora significativa en la equidad, mientras que al mismo tiempo mantienen la optimización del precio.

Desde la perspectiva del servicio al cliente, el uso de la información ha permitido generar soluciones personalizadas que ayudan al cliente a tomar mejores decisiones sobre su dinero. Este es el caso de Bconomy, una funcionalidad digital que permite a los clientes de BBVA conocer su salud financiera y aporta planes a su medida para mejorarla. La herramienta mide la evolución de los ingresos y gastos, el nivel de ahorro, el gasto en vivienda, el nivel de endeudamiento, y califica con una nota media la salud financiera del cliente. Además del diagnóstico de su salud financiera, BBVA Bconomy ayuda al cliente con recomendaciones y herramientas personalizadas en función de su situación, así como un plan de acción con medidas personalizadas para ayudarles a mejorar sus métricas. Esta herramienta incorpora además una funcionalidad conocida como

«Movimientos previstos», que, gracias al uso del *big data* y la IA, permite al cliente conocer la estimación de sus ingresos y gastos a dos meses vista para tomar decisiones sobre sus finanzas.

Otro ejemplo de asesoramiento al cliente orientado a los negocios es One View, una funcionalidad de BBVA para ofrecer a los negocios las mejores herramientas y soluciones que facilitan su gestión, y la obtención de la mejor información financiera de su empresa. Esta herramienta es un servicio de agregación financiera con el que las empresas podrán controlar todas sus cuentas nacionales, cuentas de crédito y tarjetas en un mismo sitio, en tiempo real, y a través de cualquier dispositivo, lo que les permite tener una visión global de sus cuentas, recibir alertas, acceder a informes personalizados y elegir la mejor forma de realizar sus pagos.

Estas herramientas de asesoramiento serán cada vez más importantes en la relación con los clientes en el sector financiero y serán, sin duda, fuente de ventaja competitiva en el nuevo marco financiero. Hacia estos servicios avanza el sector financiero.

### 3. Datos para el bien común

Además de las aplicaciones anteriores, los mismos datos que nutren los casos de uso indicados —en el sector financiero y en otros— hacen posible nuevos análisis de gran valor social. Analizar el impacto de desastres naturales (por ejemplo, terremotos o inundaciones); estudiar la evolución de enfermedades o epidemias para conocer mejor su diagnóstico y tratamientos médicos; entender los patrones


de desplazamiento para apoyar la planificación urbana, la seguridad vial y la gestión del tráfico, así como la protección del medio ambiente son algunos de los ejemplos donde la información de instituciones privadas puede ayudar a instituciones públicas a mejorar la toma de decisiones, la formulación de políticas, los servicios públicos o la eficiencia de los procesos administrativos.

Centrándonos en el sector financiero, dado que los datos de las transacciones bancarias proporcionan información robusta sobre la actividad económica de una manera más oportuna y con mayor granularidad que los métodos tradicionales utilizados por los institutos nacionales de estadística, el dato financiero es un activo muy valioso para generar estadísticas e indicadores oficiales de medición económica. Además de considerarse un fuerte motor para la producción estadística, esta información es de gran utilidad para organizaciones del sector público ayudándoles no solo a medir mejor la actividad, sino a comprender, evaluar, predecir y prepararse ante determinados escenarios.

En esta línea, un estudio publicado por BBVA junto con United Nations Global Pulse (Alfaro *et al.*, 2016) utiliza datos de transacciones con tarjetas para la gestión de la ayuda humanitaria. En el estudio se identifican las características descriptivas de los datos con objeto de medir el tiempo de recuperación de una zona afectada por un desastre natural como un terremoto (gráficos 9 y 10).

Concretamente, se estudió la resistencia de la población en Baja California Sur en México tras ser golpeada por el huracán


GRÁFICO 9  
**IMPACTO DEL HURACÁN ODILE EN BAJA CALIFORNIA SUR**  
 (SERIE TEMPORAL –LÍNEA NEGRA– MODELO DE «NORMALIDAD»  
 –LÍNEA DISCONTINUA–)\*



\* El día 0 corresponde al 14/09/2014, el día anterior al que el huracán tocó tierra. Panel central: impacto diario relativo con respecto al modelo de normalidad. Panel inferior: impacto acumulado.

Fuente: Alfaro et al., 2016 (BBVA).

GRÁFICO 10  
**IMPACTO DEL HURACÁN ODILE POR NIVEL DE RENTA Y GÉNERO\***



\* Diferencia entre el volumen real de transacciones y el patrón de gasto esperado el día anterior al evento.

Fuente: Alfaro et al., 2016 (BBVA).

Odile en septiembre de 2014, a través del análisis de la actividad económica antes, durante y después del desastre, con información casi en tiempo real, mejorando la capacidad de respuesta rápida de gobiernos e instituciones. El conocimiento generado de este análisis muestra el impacto económico del desastre y la capacidad de recuperación de la sociedad en la región, convirtiéndose en un apoyo para el diseño de programas y políticas de recuperación.

## VI. COMPARTICIÓN Y ACCESO A LA INFORMACIÓN

Vivimos rodeados de datos (geolocalización, transacciones financieras,...) que generan gran valor analítico y de negocio para las compañías y abren oportunidades a una mayor competencia y a la posibilidad de un mejor servicio al usuario. Estos datos son una fuente crítica que puede y debe redundar en una mejora sostenible del bienestar de las personas y deberían convertirse en una contribución necesaria de las empresas a la sociedad (Comisión Europea, 2018) a través del uso de información privada para un servicio público y la compartición de información con otras empresas.

Sobre el dato como fuente de información pública, el proceso está empezando. La Comisión Europea ha incentivado la formación de un grupo de trabajo para promover la cooperación público-privada, estableciendo un marco de referencia para lidiar con los aspectos técnicos y legales asociados a dichas colaboraciones en el contexto Europeo (Comisión Europea, 2018), además de los de negocio o so-

ciales donde se destaca que la clave del éxito de la colaboración reside en poner el foco en el uso del dato, no en la propiedad.

Entre los aspectos técnicos que hacen posible esta colaboración, la forma más común de llevarla a cabo es a través de servicios *API* accesibles a un público externo y no solo dentro de la misma organización. La monetización de datos por parte de la compañía o la figura de un facilitador técnico que se encarga de realizar el intercambio y procesamiento de los datos son otras de las vías utilizadas para compartir información entre compañías e instituciones y garantizar su calidad.

Desde un punto de vista legal, la definición de un marco de colaboración público-privado tiene que gestionar y solventar los desafíos que estas colaboraciones plantean en términos de seguridad y confidencialidad en la compartición de información, así como la potencial falta de incentivos para que las entidades privadas compartan sus datos con las administraciones públicas, toda vez que la tecnología necesaria para la generación de datos de calidad y su compartición tiene un coste y hay organizaciones que pueden considerar que la compartición pone en riesgo su ventaja competitiva.

Respecto a la compartición de datos personales entre empresas para uso competitivo, el sector financiero sirve para ilustrar las oportunidades y los riesgos asociados, pues con la entrada en vigor de la PSD2, las entidades que ofrecen servicios de pago están obligadas a dar acceso a terceros a información de pagos de sus clientes, previo consentimiento de estos, lo que posibilitará nuevos servicios

que mejorará la competencia y la experiencia de usuario. Sin embargo, la implementación de esta obligación ha dado lugar a arduos debates sobre la forma en que debe realizarse, siendo el desarrollo de *APIs* –de nuevo– percibido hoy como la solución tecnológica más viable y segura; sobre la ausencia de incentivos económicos para esta compartición, que es obligatoria y gratuita sin poder repercutirse ni siquiera el coste de la infraestructura tecnológica desarrollada para llevar a cabo esta compartición y, sobre todo, sobre el desequilibrio competitivo que ha creado para las entidades financieras, que ven cómo empresas no financieras pueden acceder a datos financieros de forma automática y en tiempo real, sin estar sometidas a una obligación de compartición recíproca.

Para evitar desequilibrios competitivos y fomentar la innovación basada en datos, es necesario un marco de compartición de información intersectorial que elimine los obstáculos actuales y, previa autorización, permita acceder a información de usuario de forma automática y en tiempo real.

## VII. VISTA HACIA EL FUTURO Y CONCLUSIONES

A lo largo de este artículo hemos tratado de ilustrar el impacto que el uso de la ciencia de datos y la inteligencia artificial han tenido en la transformación del sistema financiero, de los procesos internos de las entidades en sus análisis y del servicio al cliente.

La experiencia del cliente se ha convertido en la piedra angular de la actividad financiera y una fuen-

te de ventaja competitiva para las entidades. Los consumidores están cada vez más informados y son más exigentes, demandando servicios personalizados de mayor calidad, lo que ha supuesto un cambio de paradigma para la banca, que debe adaptarse a un nuevo cliente, entendiendo mejor su situación y hábitos financieros, ayudándole a tomar mejores decisiones y ofreciendo soluciones personalizadas.

En este contexto de cambio disruptivo será crucial, por tanto, afianzar los tres pilares básicos para la aplicación de las técnicas avanzadas de análisis de datos – la ética, la regulación y la gobernanza del dato –, que es el camino para contar con la confianza del cliente, mucho más consciente del valor de sus datos. De esta forma, la transparencia sobre el uso de la información, explicando por qué y para qué se utilizan sus datos se convertirá en un factor diferenciador entre entidades bancarias.

Por tanto, aunque en el futuro las funciones del sector financiero seguirán siendo las mismas que son hoy día, el sector seguirá experimentando importantes transformaciones en su actividad y en el servicio que ofrece, donde dominará la experiencia personalizada basada en datos.

La fusión de conjuntos dispares de datos, financieros y no financieros, permitirá disponer de una visión 360 grados del negocio bancario y las entidades contarán con información oportuna y detallada que les permitirá mejorar su capacidad de reacción ante cambios en el ecosistema.

Sin embargo, los equilibrios que se formen en el futuro en el sector, y en particular la forma

en que la innovación tendrá lugar en el sector financiero dependerá en gran medida del tipo de información al alcance de las empresas y muy especialmente del marco regulatorio. Si se favorecen modelos que pueden terminar en «un solo ganador» en que solo unas grandes empresas tienen capacidad de acceder y utilizar los datos, la competencia en el sector financiero se reducirá, los riesgos para la estabilidad financiera podrían aumentar y los costes de transición podrían terminar siendo altos. Por el contrario, si las *bigtech*, los incumbentes y las *fintech* pueden operar con igualdad en el tratamiento regulatorio y supervisor teniendo en cuenta la actividad desarrollada, el sistema financiero será más competitivo e innovador y la diversidad de actores, regulados y supervisados según la actividad desarrollada, podría ser un factor positivo para la estabilidad financiera. La regulación tendrá un rol fundamental para promover el marco de desarrollo de la competencia y el entorno de protección para el usuario y para el sistema financiero. Desde nuestro punto de vista, la intervención regulatoria se tiene que centrar en: i) establecer un marco de responsabilidad claro que genere confianza en el uso de servicios basados en IA; ii) aumentar los datos disponibles mediante la cooperación público-privada para la comparación de datos anonimizados; iii) apoyar la innovación en datos por parte de las entidades financieras eliminando barreras de acceso a infraestructuras ofrecidas por terceros para la gestión de datos, dando un tratamiento favorable a las inversiones en *software* y modificando o favoreciendo una interpretación más flexible del principio de minimización de datos recogido en

el RGPD; así como iv) fomentar la coordinación internacional para garantizar una postura armonizada sobre el uso de esta tecnología que cree un entorno competitivo equilibrado a nivel internacional.

La interacción de estos factores determinará la senda futura de un sector donde la manera de proveer servicios financieros está cambiando. El futuro del sector financiero en este nuevo entorno de uso masivo de los datos y la IA hay que enfrentarlo con decisiones que delimiten el marco de acción, las reglas de competencia entre todos los jugadores posibles y que garanticen la protección del consumidor y la estabilidad financiera; pero que permitan cubrir las necesidades de los usuarios, respetar las expectativas éticas de las sociedades y conseguir un crecimiento sostenible e inclusivo. Como siempre, pero también como nunca, dado el nuevo papel del uso de los datos masivos.

#### NOTAS

(\*) Jesús Lozano (Regulación Digital, BBVA), Tomasa Rodrigo (BBVA Research), Jorge Sicilia (BBVA Research). Los comentarios realizados en el artículo reflejan la opinión de los autores. Agradecemos a Sergio Iglesias, Álvaro Martín, Juan Murillo, Alejandro Neut, Ana Segovia y Pablo Urbiola por sus comentarios y sugerencias.

#### BIBLIOGRAFÍA

- ALFARO, E., HERNÁNDEZ, M., MAESTRE, R., MURILLO, J., PATANE, D., ZERBE, A., KIRKPATRICK, R. y LUENGO-OROZ, M. (2016). *Measuring economic resilience to natural disasters with big economic transaction data*.
- ANDREWS, D., CRISCUOLO, C. y GAL, P. (2015). *Frontier Firms, technology diffusion and public policy: micro evidence from OECD countries*. París: OECD.

AYRANCI, P., BOLÍVAR, F., CÁMARA, N., DUQUE, L., LOZANO, J., POSADAS, C., RODRIGO, T. y VÁZQUEZ, S. (2019). *El universo fintech a través de los ojos de los medios de comunicación y redes sociales*. Madrid: BBVA Research.

AZIZ, S. y DOWLING, M. (2018). AI and Machine Learning for Risk Management. *SSRN Electronic Journal*.

BAFIN (2018). *Big data meets artificial intelligence. Challenges and implications for the supervision and regulation of financial services*.

BARBA NAVARETTI, G., CALZOLARI, G. y FRANCO POZZOLO, A. (2017). *Fintech, Banks friend or foes? European Economy. Banks, Regulation, and the Real Sector*. Roma: Europeye.

BEAUCHAMP, T. y CHILDRESS, J. (1979). *Principles of Biomedical Ethics*. New York: Oxford University Press.

BERG, T., BURG, V., GOMBOVI, A. y PURI, M. (2019). On the Rise of Fintechs – Credit Scoring Using Digital Footprints. *Working Paper Series Research Paper*, n.º 18-12. Michael J. Brennan Irish Finance.

BLEI, M. y LAFFERTY, J. (2006). Dynamic Topic Models. *ICML 2006 – Proceedings of the 23rd International Conference on Machine Learning*. pp. 113-120. doi: 10.1145/1143844.1143859

BLEI, M. Y., NG, A. y JORDAN, M. (2003). Latent Dirichlet Allocation. *Journal of Machine Learning Research*, 3, pp. doi: 993-1022. 10.1162/jmlr.2003.3.4-5.993

BODAS-SAGI, D. J., GARCÍA, J. R., RODRIGO, T., RUIZ DE AGUIRRE, P., ULLOA, C., MURILLO ARIAS, J., ROMERO PALOP, J. D., VALERO LAPA, H. y PACCE, M. (2019). Measuring Retail Trade Using Card Transactional Data. *Working Paper*, 18/03. BBVA Research.

BOLÍVAR, F., DUQUE, L., ORTIZ, A. y RODRIGO, T. (2019). Disentangling risks, activity and performance through US corporate reports. Mimeo. *Working Paper*. BBVA Research.

BOSTROM, N. y YUDKOWSKY, E. (2014). The ethics of artificial intelligence. *The Cambridge Handbook of Artificial Intelligence*, pp. 316-334.



- BRESNAHAN, T. y TRAJTENBERG, M. (1996). General purpose technologies: engines of growth?. *Journal of Econometrics. Annals of Econometrics*, 65(1), pp. 83-108.
- BRYNJOLFSSON, E., ROCK, D. y SYVERSON, C. (2017). Artificial intelligence and the modern productivity paradox: a clash of expectations and statistics. The Economics of Artificial Intelligence: An Agenda. *Working Paper*, 24001. NBER.
- BBVA RESEARCH (2015). *Situación de Economía Digital*, diciembre.
- CERQUEIRA, O., DOS SANTOS, E., FERNÁNDEZ DE LIS, S., NEUT, A. y SEBASTIÁN, J. (2017). Monedas digitales emitidas por los bancos centrales: adopción y repercusiones. *Working Paper*, n.º 17/05. BBVA Research.
- COMISIÓN EUROPEA (2018). Guidance on sharing private sector data in the European data economy [COM(2018) 232 final]. *Commission Staff Working Document*, 125 final.
- CRAFTS, N. (2018). The productivity slowdown: is it the 'new normal'? *Oxford Review of Economic Policy*, 34(3), pp 443-460.
- DALY, A., HAGENDORFF, T., HUI, L., MANN, M., MARDÁ, V., WAGNER, B., WANG, W. y WITTEBORN, S. (2019). Artificial Intelligence Governance and Ethics: Global Perspectives. *Research Paper*, n.º 2019-15. The Chinese University of Hong Kong Faculty of Law.
- EHRLICH, G., HALTIWANGER, J., JARMIN, R., JOHNSON, D. y SHAPIRO, M. (2019). Re-Engineering Key National Economic Indicators. En *Big Data for 21st Century Economic Statistics National Bureau of Economic Research, Inc.* NBER.
- FERNÁNDEZ DE LIS, S. y URBIOLA, P. (2019). Transformación digital y competencia en el sector financiero. *Working Paper*, n.º 19/01. BBVA Research.
- FRAME, S., WALL, L. y LAWRENCE, J. (2018). *Technological Change and Financial Innovation in Banking: Some Implications for Fintech*. 3rd Edition. Oxford Handbook of Banking.
- FINANCIAL STABILITY BOARD, FSB (2017). *Artificial intelligence and machine learning in financial services. Market developments and financial stability implications*.
- FURMAN, J. (2019). Unlocking digital competition. *Report of the digital competition expert panel UK. Document for the Government*. London.
- FURMAN, J. y SEAMANS, R. (2018). AI and the Economy. *Innovation Policy and the Economy*, Volume 19. Lerner and Stern.
- GOLDFARB, A. y TUCKER, C. (2017). Digital Economics. *Journal of Economic Literature*, 57(1), pp. 3-43. NBER.
- GORDON, R. (2016). *The Rise and Fall of American Growth: The U.S. Standard of Living since the Civil War*. Princeton: Oxford: Princeton University Press.
- HEIL, M. (2017). Finance and productivity: A literature review. *Working Paper*, 1374. Paris: OECD Economic Dep.
- HENKE, N., BUGHIN, J., CHUI, M., MANYIKA, J., SALEH, T., WISEMAN, B. y SETHUPATHY, G. (2016). *The age of analytics: competing in a data-driven world*. McKinsey Global Institute.
- INSTITUTE OF INTERNATIONAL FINANCE, IIF (2019). Bias and Ethical Implications in Machine Learning. *Machine Learning Thematic Series Part II*.
- INTERNATIONAL ORGANIZATION OF SECURITIES COMMISSIONS, IOSCO (2017). *Research Report on Financial Technologies (Fintech)*.
- JONES, C. y TONETTI, C. (2019). Nonrivalry and the Economics of Data. *Working Paper Series*, n.º 26260. National Bureau of Economic Research.
- LEETARU, K. y SCHRODT, P. (2013). *Global Database of Events, Language, and Tone (GDELT)*.
- LESSMANN, S., BAESSENS, B., SEOW, H. V. y THOMAS, L. (2015). Benchmarking state-of-the art classification algorithms for credit scoring: An update of research. *European Journal of Operational Research*, 247(1), pp. 124-136.
- MAESTRE, R., DUQUE, J., RUBIO, A. y ARÉVALO, J. (2019). Reinforcement Learning for Fair Dynamic Pricing. En K. ARAI, S. KAPOOR y R. BHATIA (eds.), *Intelligent Systems and Applications. IntelliSys 2018. Advances in Intelligent Systems and Computing*, vol 868. Springer, Cham.
- MERTON, R. C. (1992). Financial Innovation and Economic Performance. *Journal of Applied Corporate Finance*, 4(4) (winter 1992), pp. 12-22.
- ORTIZ, A. y RODRIGO, T. (2018). How do the emerging markets' central banks talk? A big data approach to the Central Bank of Turkey. *Working Paper*, n.º 17/24. BBVA Research.
- (2018). Monitoring Global Trade Support in real time using Big Data. *BBVA Research Big Data Watch* – July 2018.
- PADILLA, J. y DE LA MANO, M. (2018). Big Tech Banking.
- PHILIPPON, T. (2017). The Fintech Opportunity. *BIS Working Paper*, n.º 655.
- ROSENBERG, M., CONFESSORE, N. y CADWALLADR, C. (2018). How Trump Consultants Exploited the Facebook Data of Millions. *The New York Times*, 17 Mar 2018.
- STEENIS, H. VAN (2019). *Future of finance. Review on the outlook for the UK financial system: what it means for the bank of England*. Bank of England.
- VARIAN, H. (2018). *Artificial Intelligence, Economics, and Industrial Organization. The Economics of Artificial Intelligence: An Agenda*. University of Chicago Press.
- VIVES, X. (2019). *Digital disruption in banking*. IESE Business School
- WEDGE, R., KANTER, J. M., VEERAMACHANENI, K., RUBIO, S. M. y PÉREZ, S. I. (2019). *Solving the False Positives Problem in Fraud Prediction Using Automated Feature Engineering*. Lecture Notes in Computer Science, vol. 11053. Springer, Cham.
- World Bank (2019). *Fintech: The Experience so Far – Executive Summary*.
- Zuiderveen, F. (2018). *Discrimination, artificial intelligence, and algorithmic decision-making*. Strasbourg: Council of Europe.



## Resumen

El *big data* y la inteligencia artificial son dos avances tecnológicos que van a mejorar la toma de decisiones de todos los agentes. La intención de este artículo es analizar la potencial aplicación por parte de los diferentes miembros de los mercados financieros, tanto de los gestores de carteras y fondos de inversión («tradicionales» y «cuantitativos») como de los asesores en banca privada. Cualquier progreso en la capacidad de conocer la realidad económica y financiera, así como de entender la reacción de las cotizaciones, de los inversores y de los clientes será útil y justificará la dedicación de recursos al estudio y la inversión en *big data*.

*Palabras clave:* *big data*, gestión de carteras, *factor investing*, gestión cuantitativa, perfilación de clientes.

## Abstract

Big data and Artificial Intelligence are two important technological developments that will improve the decision making process for all agents. The aim of this article is to analyze the potential application by the different members of the financial markets, both portfolio managers («traditional» and «quantitative» managers) and financial advisors. Any progress in the ability to know the economic and financial situation and to understand the reaction of quotes, investors and clients will be useful and will justify the commitment of resources to the study of big data.

*Keywords:* big data, portfolio management, factor investing, quantitative investment, risk profiling.

*JEL classification:* G10, G19.

# BIG DATA: UNA VISIÓN DESDE LOS MERCADOS FINANCIEROS Y LA GESTIÓN DE CARTERAS

David CANO

*Afi Inversiones Globales, SGIIC*

## I. INTRODUCCIÓN

EL *big data* ha emergido como uno de las principales revoluciones de la industria financiera. Aunque su adopción en el sector de la gestión de activos aún es muy reciente, un creciente número de participantes está analizando su aplicación para mejorar sus estrategias de inversión y profundizar en el conocimiento de sus clientes. Si bien muchas gestoras de activos han reconocido el uso del *big data*, su foco ha permanecido, de momento, en áreas como la automatización de procesos, ventas y distribución o *marketing*, sin que se cuente con experiencias sobre la aplicación en la toma de decisiones. Solo un limitado número de gestores, la mayoría *hedge funds*, han anunciado públicamente que están implantando el *big data* en sus estrategias de inversión. Y, desde luego, el número de fondos que solo usan el *big data* en su proceso de toma de decisión es, de momento, muy limitado (1).

Este artículo se estructura en cinco secciones, que coinciden con las fases del proceso de inversión y comercialización. A partir de esta introducción, se inicia con unas reflexiones sobre si el *big data* puede mejorar las predicciones de evolución de variables económicas. En la tercera sección se analiza su aplicación sobre los activos financieros, tanto los cotizados como los

no cotizados, para pasar, en la cuarta y quinta sección, a dos aplicaciones: gestión de carteras y conocimiento del cliente.

## II. BIG DATA Y SU UTILIDAD EN LA PREDICCIÓN DEL CICLO ECONÓMICO

Como firme convencido de que la evolución del ciclo económico es el mejor estimador del comportamiento de las cotizaciones de los activos financieros, al menos con una perspectiva a medio y largo plazo, considero que cualquier progreso en el diagnóstico de la posición cíclica y en la capacidad para predecir su evolución es muy positivo. En este sentido, el *big data* debe servir para contar con más indicadores fiables que ayuden a determinar mejor la posición cíclica. Pero puede ser que la principal mejoría no se produzca tanto en el «ajuste fino de los modelos», es decir, en la reducción de sus errores de estimación, sino en que permitan realizar predicciones más rápidas (en «tiempo real»). Este segundo aspecto (la actualización más frecuente de la predicción), junto con el primero (mejora de los modelos), será un avance muy significativo y tendrá un impacto claramente favorable en la gestión de carteras y en el asesoramiento a clientes.

Ahora bien, frente a este avance que implicará el *big data* en la predicción del ciclo eco-

nómico, cabe hacer las matizaciones ya clásicas a las que se enfrenta todo economista: dado que la estructura económica mundial, así como los factores que dinamizan o reducen el crecimiento, cambian de forma intensa y con alta frecuencia, podría suceder que ni siquiera con el *big data* seamos capaces de acertar con las previsiones económicas. ¿De verdad alguien cree que el *big data* habría sido capaz de anticipar, por ejemplo, el momento del inicio de la Gran Recesión de 2008? ¿Y de predecir tipos de interés negativos del euro? ¿Acaso el *big data* podría decirnos ahora cuándo volverán a ser positivas las rentabilidades de la deuda pública alemana? Hay que reconocer estas limitaciones en la capacidad predictiva de las variables económicas y financieras, pero no por ello hacer una valoración menos positiva de la mejora en el proceso que el *big data* va a implicar (lo está haciendo ya), sobre todo en la frecuencia de la predicción y en el tiempo necesario para entender y modelizar los cambios «estructurales» de la economía. El *big data* se configura como una herramienta más que va a ayudar a los economistas en el diagnóstico de la posición cíclica y en su evolución. Y, con ello, a los gestores de carteras con enfoque *global* o fundamental (2).

### III. BIG DATA Y SU APLICACIÓN EN EL ANÁLISIS DE LOS ACTIVOS FINANCIEROS

Soy un firme defensor de la gestión activa, que se basa en considerar que los precios de los activos financieros no reflejan la realidad de forma correcta durante determinados momentos del tiempo (que es cuando se ge-

| CUADRO N.º 1                                  |                                                                                  |                                                                    |
|-----------------------------------------------|----------------------------------------------------------------------------------|--------------------------------------------------------------------|
| BIG DATA Y OPORTUNIDADES EN LA GESTIÓN ACTIVA |                                                                                  |                                                                    |
|                                               | Mercado diagnostica bien la realidad                                             | Mercado diagnostica mal la realidad                                |
| El mercado anticipa bien el futuro            | No tiene sentido la gestión activa (ni el <i>big data</i> aplicado a la gestión) | Tiene sentido implantar <i>big data</i> en el proceso de inversión |
| El mercado no anticipa bien el futuro         | Tiene sentido implantar <i>big data</i> en el proceso de inversión               | Tiene sentido implantar <i>big data</i> en el proceso de inversión |

Fuente: Elaboración propia.

nera la oportunidad de compra o de venta). Y estos «fallos» se pueden producir porque «el mercado» realiza una interpretación errónea de la realidad o porque no es capaz de anticipar correctamente el futuro. En ambos casos el *big data* puede ser de utilidad (véase cuadro n.º 1): como ya hemos comentado en el punto anterior, porque puede mejorar el diagnóstico de la posición cíclica de la economía, así como la previsión de su evolución futura. Pero no solo eso, ya que en el siguiente escalón del análisis *top down* sirve para conocer mucho mejor la realidad de las empresas cotizadas.

Es decir, el *big data* debe servir para tener un mayor conocimiento y control del riesgo sistemático (medido a través de la beta de la cartera), pero también puede aplicarse al riesgo individual de cada título. Igual que en la sección anterior hemos señalado la mayor capacidad de análisis económico gracias al *big data*, consideramos que esta tesis se puede extrapolar a la renta variable y a la renta fija (el avance puede incluso ser proporcionalmente superior). Por ahora, la principal fuente de información sobre la salud de una compañía son los estados contables que publican las mismas, así como la que suministran en determinados

momentos a través de diversos canales de comunicación («relación con inversores», «hechos relevantes» o «notas de prensa»). Como sucede con el PIB, esta información es útil pero incompleta y, sobre todo, se conoce con retraso. Necesitamos contar con indicadores que permitan conocer de la forma más contemporánea posible el estado de solvencia y rentabilidad de una empresa, así como modelizar su evolución futura. Y, en nuestra opinión, el *big data* puede mejorar de forma más significativa el conocimiento de la solvencia de una compañía que la futura evolución de su cuenta de resultados. Es decir, las metodologías de *credit scoring* son las que más pueden evolucionar gracias al uso del *big data* y de ahí que pensemos que su aplicación puede ser superior en el mercado de renta fija que en el de renta variable. Por ejemplo, a la hora de modelizar los diferenciales crediticios y, con ello, tomar decisiones de inversión (si el *spread* que paga es más alto que el resultado de nuestro modelo alimentado con *big data*) o de *desinversión* (en el caso de que el diferencial sea inferior) en bonos.

En este sentido, es conveniente recordar cómo de forma creciente más compañías emiten activos de renta fija como susti-

tución a la financiación bancaria. Y en este proceso de intensificación de la desintermediación financiera, cada vez es más necesario contar con información de los emisores. Pero atención, porque de forma paralela se está produciendo otro cambio en las carteras de activos financieros, en este caso, con la creciente presencia de activos no cotizados (3). Esto es especialmente importante en la renta fija, a medida que se están desarrollando vehículos dedicados al préstamo directo (*direct lending*).

Por tanto, entendemos que el *big data* nos va a ayudar en el proceso de toma de decisiones en la gestión de carteras de activos financieros, tanto de renta variable como, especialmente, de renta fija. Y tanto en activos cotizados como, en mayor medida, en no cotizados. Los gestores de fondos de capital riesgo y de préstamos directos serán los principales usuarios del *big data* (véase cuadro n.º 2).

Sin embargo, aquí también cabe realizar matizaciones. La primera es que el *big data* debe garantizar, tanto en la recogida de datos como en su análisis, que no se incurre en el denominado *p-hacking* (Simmons) (4): el error que se comete cuando el investigador condiciona la selección de datos (por exceso o por defecto) y altera los procesos de análisis hasta que consigue los resultados deseados, es decir, hasta que sus análisis tienen la suficiente significación estadística. La obsesión por conseguir «resultados» puede llevar a cometer muchos errores Tipo II (falsos positivos). La segunda limitación es similar a la que hacíamos en la sección anterior: el *big data* nos va a ayudar en el diagnóstico y modelización de la rentabili-

| CUADRO N.º 2                                  |                                                        |                                                                       |
|-----------------------------------------------|--------------------------------------------------------|-----------------------------------------------------------------------|
| BIG DATA Y OPORTUNIDADES EN LA GESTIÓN ACTIVA |                                                        |                                                                       |
|                                               | Fondos propios ( <i>Equity</i> )                       | Financiación ajena ( <i>Debt</i> )                                    |
| Cotizado ( <i>Public</i> )                    | Fondo de inversión de RV ( <i>Equity Mutual Fund</i> ) | Fondo de inversión de RF o de préstamos ( <i>Fixed income/Loans</i> ) |
| No cotizado ( <i>Private</i> )                | Capital Riesgo ( <i>Private Equity</i> )               | Fondos de préstamos directos ( <i>Direct Lending</i> )                |

Fuente: Elaboración propia.

dad y solvencia de una empresa, pero solo de forma parcial. El abanico de aspectos que pueden condicionar tanto la cuenta de resultados de una compañía (en última instancia, principal motor de la evolución del precio) como al conjunto del mercado es muy (demasiado) amplio. Los datos son la base de todo proceso y modelo de inversión, pero está claro que es necesario contar con la visión humana y su experiencia, y ese es un ámbito al que la inteligencia artificial aún no ha conseguido llegar. Y, por último, el *big data* puede ayudar a confirmar que un activo está sobrevalorado o infravalorado, pero me temo que no a predecir el momento en el que se corregirá la situación, que es lo que verdaderamente importa cuando se gestionan carteras.

#### IV. BIG DATA Y GESTIÓN DE CARTERAS

No todos los gestores están de acuerdo conmigo en que de momento es imprescindible la inteligencia humana en el proceso de inversión y en que no es posible predecir con exactitud el momento en el que los mercados cambian sus tendencias. Podemos agrupar a estos gestores (o, al menos, a unos cuantos de ellos) dentro del colectivo «gestión cuantitativa».

Una de sus pautas comunes es el desarrollo de modelos matemáticos (algoritmos) que generen una disciplina operativa de compra y venta. Es obvio que el desarrollo del *big data* sirve para alimentar todos estos modelos. De ahí que una parte de la industria de gestión de activos considere que estamos a las puertas de un resurgimiento de este tipo de técnicas de gestión de activos. Y decimos «resurgimiento» porque, tras una época de esplendor, sonados casos de pérdidas (LTCM en 1998) o de episodios muy adversos (2008-2009; 2015-2016 y 2018) han generado dudas sobre la utilidad de estas técnicas. Aunque, como hemos señalado al principio, nuestro enfoque es *global macro*, no se debe negar la utilidad de la gestión cuantitativa. Y, en lo que respecta a la tesis central de este artículo, ambas técnicas de gestión de carteras se van a beneficiar del *big data*, al mejorar sus procesos tanto de inversión como de desinversión. Ahora bien, sin que ninguno se convierta en el método perfecto.

Si en el caso de la gestión global macro me he referido a, entre otras, las implicaciones de una estructura económica mundial cambiante o de la necesidad de la experiencia y la mente humana, en el caso de la gestión cuantitativa se debe evitar caer en un

*Mechanical Turk* (5) (Llanera, 2019). Este es uno de los factores de riesgo en los modelos cuantitativos, que pueden llevar al «programador» a introducir sesgos.

El principal problema para demostrar la utilidad del *big data* en la gestión cuantitativa es que todavía no contamos con una historia lo suficientemente larga como para poder demostrar que mejora la capacidad de predicción de los mercados financieros. Una estrategia de inversión cuantitativa sólida requiere un *back testing* durante prolongados períodos de tiempo que incluya fases muy diferentes en el comportamiento de los mercados financieros. Por lo tanto, nos encontramos en la fase de «prudencia». Es decir, se debe adoptar una actitud positiva ante la futura aplicación del *big data* en la gestión de carteras con enfoque cuantitativo, aunque, para ello, antes es necesario demostrar su utilidad. Se debe aceptar y participar en la discusión, pero de momento esperar un tiempo para su aplicación. Si en la sección anterior hemos defendido que el *big data* va a mejorar la función de gestión de activos financieros vía una mayor, mejor y más puntual información de la rentabilidad y solvencia de las compañías en las que se invierta, consideramos que

también va a mejorar el proceso de inversión, es decir, las técnicas de gestión de carteras, tanto «fundamentales» como «cuantitativas». Y si prolifera su uso, entonces emergerá la advertencia que hace todo regulador: que se intensifique el comportamiento gregario, y eventualmente procíclico, de los mercados financieros, con el consiguiente «riesgo sistémico». Pero, de momento, estamos muy lejos de tener que alarmarnos por ello.

### Factor investing

En los últimos años, la gestión de carteras, especialmente en renta variable, se está transformando en varias direcciones. Por una parte, en la distribución de activos atendiendo a criterios geográficos, que está perdiendo protagonismo a favor de un enfoque sectorial. Por otra, en los pesos relativos por activos, que se alejan de la capitalización bursátil (a diferencia de los índices, en los que la ponderación de cada acción está en función de su valor de mercado). Así, se abren paso estrategias basadas en otro tipo de análisis englobados en la denominación *Smart Beta*. Dos son los grandes grupos de estrategias que están ganando un mayor protagonismo en este

estilo de gestión: *factor investing* y megatendencias. Esta segunda se fundamenta en que las grandes tendencias económicas y sociales a nivel global son fuentes relevantes de rentabilidad en el medio y largo plazo. Por ello, es adecuado invertir en empresas o sectores que se beneficien de ellas. La longevidad, el cambio climático o la creciente relevancia de la tecnología, la digitalización o la robótica son algunas de estas megatendencias. Pero por el enfoque de este artículo, nos vamos a centrar en el *factor investing*, que defiende que varios factores son los pilares básicos de rentabilidad de los activos financieros. Estas fuentes de rentabilidad, intuitivas y de fácil entendimiento, son: rentabilidad sobre fondos propios (*ROE* [6]), valoración (*PER* [7]), volatilidad, tamaño (capitalización) y tendencia del precio o del beneficio por acción. De esta forma, surge la inversión por los siguientes factores: *quality*, *value*, *low volatility*, *size* y *momentum* que lleva a sobreponderar las acciones que tengan mayor *ROE* o menor *PER*, o una reducida volatilidad, o una capitalización media o, por último, estén experimentando un mejor comportamiento de su beneficio o de su cotización (véase cuadro n.º 3).

CUADRO N.º 3

#### PRINCIPALES PARÁMETROS DEL FACTOR INVESTING

|           | QUALITY                                     | VALUE                                       | LOW VOLATILITY                                   | SIZE                                                                                            | MOMENTUM                                                                                        |
|-----------|---------------------------------------------|---------------------------------------------|--------------------------------------------------|-------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------|
| Indicador | ROE                                         | PER                                         | Volatilidad realizada del precio                 | Capitalización                                                                                  | Evolución del precio<br>Evolución del beneficio por acción                                      |
| Criterio  | Sobreponderar compañías con el ROE más alto | Sobreponderar compañías con el PER más bajo | Sobreponderar compañías con la menor volatilidad | Sobreponderar compañías con una capitalización medio (evitar la más grandes y las más pequeñas) | Sobreponderar compañías cuyo precio o beneficio más está subiendo en los últimos meses (3 ó 12) |

Fuente: Elaboración propia.



El *factor investing* se revela como una técnica de gestión mixta entre un enfoque fundamental (utiliza parámetros como *ROE*, *PER*, beneficio por acción) y uno cuantitativo, ya que apenas interviene la opinión del gestor, que se guía, en un proceso bastante disciplinado, por los parámetros de cada acción (8). Consideramos que el *big data* puede ser una palanca de mejora en *factor investing*, tanto por favorecer el proceso de toma de datos como de identificación de nuevos factores.

#### V. BIG DATA APLICADO A LA PERFILACIÓN DE CLIENTES Y LA PREDICCIÓN DE SU COMPORTAMIENTO

Hasta ahora hemos analizado el proceso de toma de decisiones en los mercados financieros. Es tiempo de entrar en el último eslabón, es decir, la relación con el cliente. Para realizar un correcto asesoramiento en materia de inversión es imprescindible conocer las pautas de decisión y de reacción de los clientes (en especial, en los momentos en los que aumenta la volatilidad y se sufren pérdidas). Conscientes de que en ambos casos no suele dominar la racionalidad, a lo largo de los últimos años se ha intensificado la aceptación del denominado *behavioral economics* y *behavioral finance* (9). Incluso la normativa ha adoptado este sesgo mediante la realización obligatoria por parte de los clientes de test de conveniencia y de idoneidad. La intención es aumentar el conocimiento del cliente por parte del asesor (y, tal vez, que el propio cliente se conozca a sí mismo), así como el ajuste del producto con su nivel de riesgo,

horizonte temporal, expectativas de rentabilidad, etc. Pero estos test, por pura practicidad, no pueden ser muy extensos (no más de diez o quince preguntas, muchas de las cuales, por «educación», apenas profundizan en los aspectos relevantes); es obvio que se quedan muy cortos para conocer los parámetros más importantes a la hora de recomendar una cartera y su nivel de riesgo. Surge aquí la utilidad del *big data* que, como es sabido (Llanera, 2019), tiene sus inconvenientes y sus detractores: «Nuestra identidad digital es más completa, rugosa y precisa que el yo que creemos que somos. Incluye todos aquellos elementos de nuestro carácter que, aunque deseemos no tenerlos, existen. En el mundo de los datos, somos más nuestros dobles digitales que nosotros mismos».

Pero en nuestra opinión el *big data* puede ayudar a conocer de verdad al cliente. ¿Acaso no preferiría que le pudieran ofrecer, sin necesidad de que le hicieran más preguntas ni rellenar más formularios, una cartera de activos financieros que se ajustasen perfectamente a sus intereses, personalidad, hábitos de vida y circunstancias personales? Ello, sin menoscabo de que deba existir, y se garantice, el «derecho a volar por debajo del radar» y la seguridad de los datos. Y, para ello, es necesario que se intensifique la regulación sobre cómo se recaban y usan los datos, así como quién los usa.

Con todo, hecha esta advertencia, creo que el *big data* tiene una enorme utilidad en el proceso de *perfilamiento del cliente*, así como en otras tareas vinculadas con el cumplimiento normativo.

#### VI. CONCLUSIONES

Inmersos en el desarrollo tecnológico, es obvio que todos los agentes y sectores deben tener una actitud atenta y positiva ante las innovaciones, una predisposición a su adopción, así como para destinar recursos a la investigación y puesta en marcha. Está claro que el sector financiero es uno de los más afectados y, dentro de él, la gestión de activos, en una doble vertiente: toma de decisiones y asesoramiento de clientes. En ambos casos, el *big data* debe ayudar a tomar mejores decisiones y también, aunque de forma menos disruptiva, a reducir costes. Por lo que respecta a la gestión de activos, el uso del *big data* es todavía reducido, tal vez porque el contraste de la eficacia de los modelos no es, por su horizonte temporal, lo suficientemente largo. Pero consideramos que a medida que se avance en su disponibilidad se incorporará en los procesos de toma de decisiones. Es decir, consideramos el *big data* como una herramienta más que se usará de forma habitual, como ahora es común utilizar índices de sentimiento, algo inimaginable hace tres o cuatro décadas, por ejemplo. Y podrá ser un dinamizador de los modelos cuantitativos, que podrán mejorar sus algoritmos. Por último, el uso del *big data* no se limitará a los activos cotizados, sino que es posible que su uso se haga más frecuente en los no cotizados (*private equity* y *direct lending*), donde hay menos información. Ahora bien, la aplicación no es, ni mucho menos, generalizada. Estamos en la fase «*let's see how it works*» que pensamos que culminará con la aplicación universal por parte de todos los agentes. El *big data*



se incorporará en el proceso de toma de decisiones, pero como una pieza más dentro del proceso, tanto en los gestores global macro como en los cuantitativos. Por suerte o por desgracia, tanto la economía como los mercados financieros sufrirán siempre cambios estructurales que hagan imposible su perfecta modelización y predicción. Y porque, además, surgirán nuevos factores que impacten sobre las variables económicas y las cotizaciones y su incidencia no siempre será la misma. Respecto al grado de conocimiento del cliente, supondrá un claro avance, aunque siempre condicionado a que se cuente con su autorización. Con todo, el cliente debe ser consciente de que sucede como con el médico: cuanto más se sepa de él, más eficaz será el tratamiento recomendado por ajustarse en mayor medida a su situación particular.

## NOTAS

(1) El dato localizado hace referencia a un informe del Financial Stability Board de noviembre de 2017 que cuantifica en 10.000 millones de dólares los activos gestionados usando metodologías de *big data* y *machine learning*.

(2) En CANO (2018) se comentan dos índices de riesgo económico elaborados a partir de *big data*.

(3) Y de vehículos de inversión en activos no cotizados.

(4) También conocido como *data dredging*, *data fishing* o *data snooping*.

(5) En 1970, el inventor húngaro W. VON KEMPELEN construyó una máquina de ajedrez conocida como *Mechanical Turk*, que era capaz de jugar al ajedrez contra humanos. Tuvo un éxito espectacular dado que ganaba la mayoría de partidas. Pero en realidad era una ilusión que permitía a un maestro de ajedrez humano esconderse dentro de la máquina y operarla.

(6) ROE: beneficio / fondos propios.

(7) PER: precio de la acción / beneficio por acción.

(8) Además, suele equiponderar los títulos en los que invierte, a diferencia de los gestores pasivos –y también la mayoría de activos– que asignan pesos en función de la capitalización.

(9) No debe pensarse que los sesgos se producen solo entre los «clientes finales», ya que los inversores profesionales también los sufren.

## BIBLIOGRAFÍA

BLITZ, D. y VAN BOMMEL, R. (2018). Big data and AI pose many challenges for quant investors. Robeco Insights, junio.

CANO MARTÍNEZ, D. (2018). Riesgos políticos, económicos y financieros. Índices y evolución reciente. *Boletín de Estudios Económicos*, 225. Deusto Business Alumni.

— (2019). Big (good) data. *El Alcázar de las Ideas*. Julio. <https://elalcazardelasideas.blogspot.com/2019/07/big-good-data.html>

FERNÁNDEZ, A. (2019). Inteligencia artificial en los servicios financieros. *Boletín Económico*, 2/2019. Banco de España.

GOLDMAN SACHS (2016). *The Role of Big Data in Investing*. Julio.

LLANERA, P. (2019). *Datanomics*. Deusto.

## ANEXO

### RECUADRO 1

#### CÓMO POSICIONAR UNA CARTERA DE ACTIVOS HACIA EL *BIG DATA*

Uno de los retos de todo gestor activo de carteras es cómo obtener rentabilidades positivas de sus ideas de inversión. Y decimos «retos» porque no es tan obvio como parece. Uno de los ejemplos más claros es considerar que el PIB de una determinada economía va a experimentar un fuerte crecimiento o, al menos, diferencial con el resto de países. La respuesta natural sería: «invierta en el mercado bursátil de ese país». Pues es posible que no sea la decisión más acertada si las compañías que más ponderan en él no tienen una alta vinculación con el PIB, bien porque, por ejemplo, sean multinacionales, bien porque no pertenezcan a los sectores *tractores* de la economía. Cuando la estructura sectorial de un mercado bursátil tiene poco que ver con la del PIB, las estrategias *top down* no sirven. El ejemplo más claro es la evolución del PIB español entre el 2012 y el 2019 comparado con el Ibex 35. Otro caso es el desarrollo de las economías emergentes. ¿Cuál es la mejor forma de posicionar las carteras? ¿Mediante multinacionales de países desarrollados que tienen una importante cuota de sus ingresos en economías emergentes o mediante empresas cotizadas de esos países emergentes? No existe consenso y la evidencia empírica da la razón (y se la quita) a los dos contendientes en el debate. Creo que este dilema se puede aplicar a dos de las principales innovaciones tecnológicas: el *big data* del que hablamos en este artículo y el *blockchain*. Si creemos que van a ser dos ganadores del futuro, ¿cómo debemos implantarlas en nuestra cartera? ¿Comprando compañías que desarrollen estas tecnologías o empresas que las usen para su operativa y que con su aplicación obtengan una ventaja competitiva? Tal vez porque el censo de compañías tecnológicas que desarrollan tanto *big data* como *blockchain* es reducido (al menos en el caso de las cotizadas), el sesgo que se observa en los fondos de inversión especializados es, de momento, más de empresas «usuarias» que de empresas «desarrolladoras». Una situación distinta se puede observar en fondos de capital riesgo (en especial, en los *venture capital*) pero su número es limitado, así como sus patrimonios gestionados.

### CUADRO N.º 1

#### OBJETIVOS Y POLÍTICA DE INVERSIÓN (\*)

*Objetivo de inversión:* El objetivo del subfondo es superar la rentabilidad del MSCI World Index durante un período de inversión de cinco años, invirtiendo en los mercados de capitales internacionales y mediante la selección, entre otras, de empresas que participan en sectores tecnológicos o relacionados con las tecnologías de análisis avanzado (*big data*).

(\*) El fondo tiene ISIN LU1244893696.

### CUADRO N.º 2

#### COMPOSICIÓN DE LA CARTERA (\*)

| ACCIÓN                                      | % EN LA CARTERA | PAÍS    | PER   |
|---------------------------------------------|-----------------|---------|-------|
| Alphabet Inc A                              | 5,40            | EE.UU.  | 23,70 |
| Orange Espagne S.A.U.                       | 4,29            | Francia | 19,13 |
| International Business Machines Corporation | 3,90            | EE.UU.  | 13,73 |
| JPMorgan Chase & Co.                        | 3,63            | EE.UU.  | 10,90 |
| Schlumberger Ltd.                           | 3,60            | EE.UU.  | 21,22 |
| AXA SA                                      | 3,45            | Francia | 21,53 |
| Randstad NV                                 | 3,36            | Holanda | 11,35 |
| NetApp Inc.                                 | 3,25            | EE.UU.  | 12,07 |
| Nasdaq Inc.                                 | 3,23            | EE.UU.  | 30,50 |
| Sony Corporation                            | 3,19            | Japón   | 9,04  |
| FedEx Corporation                           | 3,15            | EE.UU.  | 75,46 |

*Fuente:* Observatorio de la Digitalización Financiera de Funcas.


(\*) El fondo tiene ISIN LU1244893696.

## RECUADRO 2

## LA IMPORTANCIA DE LOS FLUJOS DE INVERSIÓN Y DESINVERSIÓN

Uno de los factores directores en la evolución de los mercados financieros son los flujos de inversión y la liquidez. Fuertes entradas (y salidas) de capitales suelen venir acompañadas de revalorizaciones (y caídas) del precio de los activos, en una reacción que suele ser más intensa cuanto menos líquido y menos profundo es el activo en cuestión. Resulta sorprendente que uno de los aspectos más importantes en la evolución de los mercados (flujos y liquidez) no esté cubierto ni en cantidad, ni en calidad de información. Los datos de los que disponemos son de escasa calidad (muchos son meras encuestas), de difícil acceso y de muy tardía disponibilidad (entre 6, 12 y hasta 24 meses). Este es, sin duda, uno de los ámbitos en los que el *big data* puede ser tremendamente útil para la gestión de activos: una predicción en tiempo real de los flujos de inversión en cada uno de los activos financieros cotizados y no cotizados, así como indicadores del grado de liquidez de los mercados (sobre todo cuando esta cae).

GRÁFICO 1  
MAPA DE CALOR (INDICADORES DE LIQUIDEZ)



Fuente: [www.liquidity.com](http://www.liquidity.com)

---

COLABORACIONES

### **III.**

## **EXPERIENCIAS Y CASOS**

## Resumen

El sector bancario está sometido a un continuo proceso de transformación tecnológica. Este artículo examina la evolución y principales características de dicha transformación resaltando su carácter global y su futura aceleración. Además, el artículo se centra en un conjunto de nuevas tecnologías –análisis masivo de datos (*big data*), inteligencia artificial (IA), tecnología de registro descentralizado (*blockchain*) y computación en la nube (*cloud computing*)– cuya implementación configura una «nueva tecnología bancaria». El análisis de la adopción de esta nueva tecnología en la banca europea refleja una cierta correlación positiva entre su adopción, la rentabilidad bancaria y la capacidad de generar ingresos.

*Palabras clave:* tecnología, banca, *big data*, inteligencia artificial, nube, *blockchain*.

## Abstract

The banking sector is undergoing a continuous process of technological transformation. This article examines the evolution and main characteristics of this transformation highlighting its global character and future acceleration. In addition, the article focuses on a set of new technologies –analysis of massive data (*bigdata*), artificial intelligence (AI), decentralized registration technology (*blockchain*) and cloud computing– whose implementation configures a «new banking technology». An examination of the adoption of this new technology in the European banking industry reflects a certain positive correlation between its adoption, bank profitability and banks' ability to generate income.

*Keywords:* technology, banking, big data, artificial intelligence, cloud, blockchain.

*JEL classification:* G21, O30.

# LA NUEVA TECNOLOGÍA BANCARIA: APLICACIONES, ADOPCIÓN E IMPACTO EN BANCA

Pedro J. CUADROS-SOLAS

CUNEF

## I. INTRODUCCIÓN

AUNQUE en esencia la actividad bancaria de intermediación financiera se mantiene desde el nacimiento de la banca moderna en el norte de Italia a finales del período medieval y principios del Renacimiento, el sector bancario se ha caracterizado por estar sometido a un continuo proceso de cambio. En la actualidad, dicho proceso parece venir marcado por una revolución tecnológica (Stiglitz, 2017). Dicha transformación no es nueva para el sector, ya que siempre ha sido uno de los sectores de actividad donde el componente tecnológico ha tenido un mayor peso.

A lo largo del tiempo se han sucedido numerosos cambios tecnológicos en el sector bancario que han servido para modernizar la forma en que las entidades bancarias realizan la actividad de intermediación financiera. Muchas de estas «revoluciones» tecnológicas se han sucedido en las últimas décadas –implantación de los cajeros automáticos en los años ochenta, la implantación de la banca en línea desde finales de los noventa y la adopción de la banca móvil con la difusión de los teléfonos inteligentes a partir de 2008–, pero en la actualidad el potencial de la tecnología para impregnar todo el negocio bancario parece aún más evidente. El desarrollo de nuevas tecnologías que per-

miten el análisis masivo de datos (*big data*), la inteligencia artificial (IA), la tecnología de registro descentralizado (*blockchain*) y la computación en la nube (*cloud computing*) empiezan a configurar una «nueva tecnología bancaria», susceptible de tener un impacto en la actividad bancaria mayor que el de anteriores tecnologías. La implantación, adopción y uso de esta nueva tecnología bancaria tiene la capacidad de alterar la oferta –con bancos más digitales y con la llegada de nuevos proveedores tecnológicos capaces de ofrecer servicios financieros– y la demanda de servicios bancarios –con clientes más digitalizados–.

Por lo que respecta a la industria, la adopción de estas nuevas tecnologías está alterando muchos de los procesos internos permitiendo que las entidades bancarias puedan prestar sus servicios más eficientemente. Además, los consumidores también han avanzado en su grado de digitalización financiera al tiempo que lo hace su entidad, de manera que la interacción banco-cliente comienza a orientarse al canal digital. Es por ello, que además de los propios efectos internos que las nuevas tecnologías bancarias puedan tener para las propias entidades financieras (en eficiencia o rentabilidad), también comienzan a valorarse los efectos que esta nueva tecnología bancaria tenga en los consumidores (mayor digitaliza-



ción y/o exclusión financiera) y en la economía real (en términos de empleo en el sector bancario).

Este cambio tecnológico en la oferta y la demanda de servicios financieros es fruto del liderazgo en el gasto tecnológico que protagonizan las entidades bancarias. El sector financiero continúa aumentando año tras año, con tasas de crecimiento del presupuesto tecnológico superiores al del resto de industrias (Computer Economics, 2019). Dicho proceso de transformación tecnológica de la industria bancaria se caracteriza por estar sometido a una continua aceleración y por su carácter global. Las estimaciones apuntan a que el proceso de cambio tecnológico de la industria bancaria se está acelerando pues las tasas de crecimiento futuras del gasto tecnológico superarán a las actuales. Además, aunque puedan existir diferencias entre entidades, un examen de las principales regiones –Norteamérica, Europa y Asia-Pacífico– muestra que dicho proceso es común en el sector bancario mundial. Asimismo, parece retroalimentarse, al observarse correlaciones positivas entre el gasto tecnológico y la tasa de crecimiento del mismo. De manera que, aquellos bancos con mayores gastos tecnológicos son los que presentan tasas de crecimiento más elevadas.

Una parte importante de dicho gasto tecnológico, cerca del 26 por 100, se destina a las tecnologías más innovadoras. Desde el propio sector se identifican a cuatro tecnologías como las más disruptivas: *big data*, inteligencia artificial, *blockchain* y *cloud computing*. Su uso combinado es lo que se conoce como la «nueva tecnología bancaria». Aunque sus aplicaciones en

banca son muy amplias, se constata que actualmente se orientan principalmente en: fortalecer el posicionamiento competitivo, mejorar directamente la experiencia de los clientes y en mejorar la eficiencia operativa. El potencial de dicha nueva tecnología bancaria hace que además de los proyectos individuales de cada entidad, también nacen proyectos globales participados por un conjunto de entidades bancarias. En la banca europea es el caso de proyectos como We.trade, Marco Polo, Komgo o Trade Information Network, que haciendo uso de estas cuatro tecnologías disruptivas están permitiendo a las entidades participantes afrontar retos tecnológicos superiores a los que podrían acometer por separado.

Además, como podría esperarse, la adopción de la nueva tecnología bancaria parece tener un impacto para las entidades financieras. Como se evidencia en el artículo, existen diferencias entre las entidades bancarias en función del grado en que han adoptado la nueva tecnología bancaria. Aunque no pueden inferirse una relación de causalidad, sí parecen existir evidencias a favor de una cierta correlación positiva entre la adopción de las nuevas tecnologías, la rentabilidad bancaria y la capacidad de generar ingresos.

El artículo se estructura en cinco secciones que siguen a esta introducción. En la segunda sección se hace un repaso por la literatura que analiza el impacto de la tecnología en la actividad bancaria. En la sección tercera se aporta una visión descriptiva del gasto tecnológico en el sector bancario. Los usos potenciales en banca de las nuevas tecnologías más disruptivas –*big data*, la

inteligencia artificial, *blockchain* y computación en la nube– se analizan en la cuarta sección. La quinta sección examina los proyectos globales en la banca europea que emplean dichas tecnologías y además, partiendo de un análisis textual, se analizan diferencias entre las entidades bancarias en función del grado en que han adoptado la nueva tecnología bancaria. Finalmente, la última sección presenta las conclusiones finales.

## II. ANÁLISIS DEL IMPACTO DE LA TECNOLOGÍA EN LA ACTIVIDAD BANCARIA

Aunque el impacto de la tecnología en la actividad de intermediación financiera que desarrollan los bancos ya ha sido objeto de estudio, en las últimas décadas ha cobrado una mayor relevancia. El papel que la tecnología juega en los servicios bancarios se ha ido acrecentando a medida que tanto bancos como consumidores han ido incorporando la tecnología a su día a día.

La teoría económica ha subrayado el impacto que la tecnología tiene en la rentabilidad bancaria mediante la reducción de los costes. Las innovaciones tecnológicas tienen la capacidad de reducir los costes bancarios a partir de un mejor procesamiento de las transacciones, racionalizando las estructuras de producción y distribución, estandarizando procesos bancarios y alcanzando economías de escala derivadas de la centralización de la recopilación de información. Aunque la teoría económica predice el impacto positivo de la tecnología en el desempeño de la actividad bancaria desde hace tiempo se argumenta la

existencia de la «paradoja de la productividad». Esta paradoja, inicialmente formulada por Robert Solow, evidencia que la transformación tecnológica no se traduce en ganancias de productividad, lo que se traduce en un limitado impacto de las inversiones tecnológicas de los bancos en su rentabilidad. En cualquier caso, como señala Berger (2003), existen varias dificultades para vincular el progreso tecnológico con el crecimiento de la productividad porque el progreso tecnológico suele ser difícil de cuantificar.

La evidencia empírica en la relación entre tecnología y rentabilidad no está clara. Algunos estudios empíricos, la mayoría desarrollados con datos anteriores al año 2000, no encuentran relación alguna entre tecnología y rentabilidad, mientras que otros han documentado un efecto positivo. Markus y Soh (1993) estudian el impacto del gasto tecnológico de los bancos en la rentabilidad en los años ochenta y concluyen que para los bancos más pequeños las inversiones en tecnología no se traducen en mayores beneficios. Por su parte, Beccalli (2007) se centra en estudiar la banca europea durante el período 1995-2000, documentando un efecto heterogéneo de la tecnología. Mientras que las tecnologías externalizadas, ofrecidas por terceros proveedores, tienen un efecto positivo sobre los beneficios, la simple adquisición de *hardware* y *software* por el banco reduce la rentabilidad. Otros estudios han documentado el impacto económico de las inversiones en tecnología. Casolaro y Gobbi (2007) usando una amplia muestra de bancos italianos muestran que las inversiones tecnológicas han permitido a los bancos reducir sus costes

en un 1,3 por 100 anualmente y aumentar las ganancias a corto plazo en un 2 por 100. Por su parte, Kozak (2005) examina la industria bancaria de Estados Unidos durante el período 1992–2003 mostrando una correlación positiva entre las inversiones tecnológicas que realizan los bancos y su rentabilidad. Por otra parte, para la región de Asia-Pacífico, Chowdhury (2003) muestra que, las inversiones tecnológicas para la mejora del capital y del trabajo tienen un efecto positivo estadísticamente significativo en la productividad y rentabilidad de los bancos.

Más recientemente, algunos estudios han examinado el impacto de la tecnología a raíz de la digitalización bancaria, tratando de relacionar la adopción de la banca *online* y de la banca móvil con la competencia y el rendimiento bancario. Desde el lado de la industria, Hernández-Murillo, Llobet y Fuentes (2010) muestran que la adopción por parte de los bancos de nuevas tecnologías, como los servicios de banca en línea, se debe en parte a la adopción de la tecnología por parte de sus competidores. Mientras que desde la vertiente del cliente bancario, Xue, Hitt y Chen (2011) muestran que cuando los consumidores se digitalizan estos adquieren más productos del banco y realizan más transacciones a través de diferentes canales. Además, Carbó-Valverde, Cuadros-Solas y Rodríguez-Fernández (2019) estudian cómo las inversiones en tecnología de los bancos afectan la digitalización de los clientes utilizando datos de clientes bancarios. Después de considerar un conjunto de factores, el estudio muestra que las inversiones de los bancos en tecnología afectan positivamente la digitaliza-

ción de los clientes bancarios. En esta misma línea, Campbell y Frei (2010) han documentado una relación positiva entre la adopción de la banca *online* por parte de la entidad bancaria, el uso de dicho canal por los clientes y la retención de los mismos. Igualmente, Deyoung, Lang y Nolle (2007), He (2015), Hernando y Nieto (2007) han evaluado el impacto que tiene que los clientes bancarios adopten la tecnología en la rentabilidad bancaria. Estos estudios concluyen que la banca en línea tiene un efecto positivo en el rendimiento bancario, al ser un canal complementario y no sustitutivo de las sucursales bancarias.

Finalmente, otros estudios que han examinado el impacto de innovaciones tecnológicas concretas como la adopción de los cajeros automáticos (Haynes y Thompson, 2000) o del sistema de pagos interbancarios SWIFT (Scott, Reenen y Zachariadis, 2017) muestran su efecto positivo en la productividad y en la rentabilidad bancaria a largo plazo.

### III. EL GASTO TECNOLÓGICO DEL SECTOR BANCARIO

#### 1. Gasto tecnológico a nivel agregado

La transformación tecnológica está llevando a un cambio de paradigma económico que afecta a todas las industrias (Stiglitz, 2017). La tasa de crecimiento anual compuesta del gasto mundial en tecnología se estima que alcanzará el 5,1 por 100 para el período 2016-2021 (IDC, 2018). El sector financiero, y en particular la industria bancaria, han destacado por liderar la transformación tecnológica

además de en términos agregados por haber adoptado más rápido nuevas tecnologías. La evidencia reciente muestra que la respuesta del sector financiero, medida mediante el gasto tecnológico, está siendo superior al del resto de industrias. En 2018, el sector financiero aumentó su presupuesto tecnológico aproximadamente un 3 por 100, lo que está por encima de la mediana de todas las industrias (Computer Economics, 2019). Los datos más recientes de 2018 muestran que dentro de la industria financiera, el gasto tecnológico se sitúa entre el 4,4 por 100 y el 11,4 por 100 de los ingresos. Además, como muestra el gráfico 1, la industria de servicios financieros presenta los mayores ratios de gasto tecnológico en comparación a otras industrias. En dicho gráfico se muestran los valores de gasto tecnológico entre los que oscilan percentiles 25 y 75. Cada empresa de la industria gastó en 2018 entre 13.772 y 26.667 dólares por cliente. Asimismo, el sector financiero también destaca frente al resto de industrias por su mayor gasto tecnológico por puesto de trabajo. Estas cifras evidencian el liderazgo en materia de gasto tecnológico del sector financiero en relación a otros sectores de actividad.


Centrándonos en el sector bancario, aunque tradicionalmente las innovaciones tecnológicas han sido un componente esencial de la estrategia bancaria, la penetración de la tecnología en dicho sector ha crecido en la última década. En este sentido, el avance tecnológico al que se ha visto sometida la sociedad durante las últimas décadas –con el desarrollo de nuevas tecnologías, la mejora de las infraestructuras existentes y la difusión en el uso

de la tecnología– ha empujado al sector bancario a acometer un proceso de transformación tecnológica.

El gráfico 2 refleja el crecimiento a nivel agregado del gasto tecnológico en el sector bancario durante el período 2013-2017 en Norteamérica, Europa y Asia-Pacífico. Durante este período el gasto tecnológico habría crecido un 19,7 por 100, lo que supone una tasa de crecimiento anual del 4,6 por 100.


Así, en el año 2017 los bancos a nivel mundial habrían destinado 215.000 millones de dólares a tecnología, una cifra que supera el 16 por 100 del PIB de España. Además, se estima que el 26 por 100 de este gasto tecnológico va destinado a tecnologías innovadoras, lo que se traduce en que tres de cada cuatro euros destinados a la tecnología se dedican a la adopción, mejora y desarrollo de tecnologías ya existentes. Aunque las cifras ya son importantes, se espera que con-

**GRÁFICO 1**  
**COMPARATIVA DEL GASTO TECNOLÓGICO POR SECTORES (2018)**



Fuente: Computer Economics y elaboración propia.

**GRÁFICO 2**  
**EVOLUCIÓN DEL GASTO TECNOLÓGICO EN LA BANCA (2013- 2017)**



Fuente: Statista y elaboración propia.


tiñen creciendo en los próximos años. La consultora global Celent ha estimado que en el período 2019-2022, el gasto tecnológico pueda crecer un 14,4 por 100, a un ritmo anual superior al 4,5 por 100. Estas tasas de crecimiento llevarían el gasto

en tecnología por encima de los 300.000 millones de dólares.

El fenómeno tecnológico en la banca, además de por su continua aceleración, se caracteriza por su carácter global. Actualmente, como se recoge en

el gráfico 3, la mayor parte del gasto lo protagonizarían los bancos norteamericanos (un 38 por 100), seguidos de los europeos (un 29 por 100) y los asiáticos (un 25 por 100). En todas las regiones se observa un crecimiento del gasto tecnológico. Si bien, las predicciones muestran que los bancos de la región Asia-Pacífico serían los que más aumentarían su gasto con una tasa de crecimiento anual superior al 5,2 por 100, muy seguidos de los europeos con un crecimiento anual del 4,9 por 100.

**GRÁFICO 3**  
**ESTIMACIÓN DE LA EVOLUCIÓN DEL GASTO TECNOLÓGICO EN LA BANCA POR REGIONES (2019 – 2022)**



Fuente: Celent y elaboración propia.

**GRÁFICO 4**  
**CORRELACIÓN ENTRE EL GASTO TECNOLÓGICO Y SU TASA DE VARIACIÓN**



## 2. Gasto tecnológico por entidad bancaria

En cualquier caso, el análisis global del sector no puede obviar la existencia de importantes diferencias entre entidades bancarias. Para poder analizar estas diferencias hemos obtenido el gasto tecnológico en los años 2017 y 2018 para un conjunto de bancos representativos del sector. Esta información a nivel microeconómico, obtenida a partir de las cuentas anuales publicadas por las entidades bancarias, pretende ayudar a comprender cuál es el grado de heterogeneidad en el gasto tecnológico a nivel mundial. La muestra se compone de 46 grandes bancos de Norteamérica, la región Asia-Pacífico y Europa que superan los 50.000 millones de activos, por tanto, con un peso específico en el sistema financiero internacional. Dicha muestra pretende ser representativa del sistema financiero internacional. El cuadro n.º 1 recoge cuáles son los bancos objeto de la muestra y el tamaño de los mismos en función de sus activos totales en miles de millones de dólares a final de 2018.

CUADRO N.º 1

## BANCOS DE LA MUESTRA SOBRE EL GASTO TECNOLÓGICO

| BANCO                   | PAÍS           | TAMAÑO (MILES DE MILLONES DE DÓLARES) |
|-------------------------|----------------|---------------------------------------|
| <b>ASIA-PACIFICO</b>    |                |                                       |
| ANZ                     | Australia      | 50 - 250                              |
| CommonWealth Bank       | Australia      | 500 - 1.000                           |
| National Bank Australia | Australia      | 500 - 1.000                           |
| Mitsubishi UFJ          | Japón          | 1.000 - 3.000                         |
| DBS                     | Singapur       | 250 - 500                             |
| <b>NORTEAMÉRICA</b>     |                |                                       |
| CIBC                    | Canadá         | 250 - 500                             |
| ScotiaBank              | Canadá         | 500 - 1.000                           |
| Citigroup               | Estados Unidos | 1.000 - 3.000                         |
| State Street Corp.      | Estados Unidos | 50 - 250                              |
| JP Morgan               | Estados Unidos | 1.000 - 3.000                         |
| Wells Fargo             | Estados Unidos | 1.000 - 3.000                         |
| Bank of America         | Estados Unidos | 1.000 - 3.000                         |
| Bank NY Mellon          | Estados Unidos | 250 - 500                             |
| Morgan Stanley          | Estados Unidos | 500 - 1.000                           |
| Goldman Sachs           | Estados Unidos | 500 - 1.000                           |
| <b>EUROPA</b>           |                |                                       |
| Raiffeisen Bank Intl    | Austria        | 50 - 250                              |
| Erste Group Bank        | Austria        | 250 - 500                             |
| ABN AMRO                | Bélgica        | 250 - 500                             |
| Belfius Banque          | Bélgica        | 50 - 250                              |
| Jyske Bank              | Dinamarca      | 50 - 250                              |
| OP Financial Group      | Finlandia      | 50 - 250                              |
| Société Générale        | Francia        | 1.000 - 3.000                         |
| Norddeutsche LB         | Alemania       | 50 - 250                              |
| Deutsche Bank           | Alemania       | 1.000 - 3.000                         |
| BayernLB                | Alemania       | 250 - 500                             |
| LBBW                    | Alemania       | 250 - 500                             |
| DZ Bank                 | Alemania       | 500 - 1.000 mil millones              |
| Commerzbank             | Alemania       | 500 - 1.000 mil millones              |
| Bank of Ireland         | Irlanda        | 50 - 250 mil millones                 |
| Unicredit               | Italia         | 500 - 1.000 mil millones              |
| Intesa Sanpaolo         | Italia         | 500 - 1.000 mil millones              |
| Cooperative Rabobank    | Países Bajos   | 500 - 1.000 mil millones              |
| ING                     | Países Bajos   | 1.000 - 3.000 mil millones            |
| DNB Bank                | Noruega        | 250 - 500 mil millones                |
| Powszechna Kasa Osz.    | Polonia        | 50 - 250 mil millones                 |
| Banco de Sabadell       | España         | 250 - 500 mil millones                |
| BBVA                    | España         | 500 - 1.000 mil millones              |
| CaixaBank               | España         | 250 - 500 mil millones                |
| Banco Santander         | España         | 1.000 - 3.000 mil millones            |
| SEB                     | Suecia         | 250 - 500 mil millones                |
| Swedbank                | Suecia         | 250 - 500 mil millones                |
| Svenska Handelsbanken   | Suecia         | 250 - 500 mil millones                |
| Nordea Bank Group       | Suecia         | 500 - 1.000 mil millones              |
| UBS                     | Suiza          | 500 - 1.000 mil millones              |
| Credit Suisse           | Suiza          | 500 - 1.000 mil millones              |
| Lloyds Banking Group    | Reino Unido    | 500 - 1.000 mil millones              |
|                         | Media          | 11,85 por 100                         |
| Gasto tecnológico       | Mediana        | 10,75 por 100                         |
|                         | Percentil 25 - | 7,99 por 100 -                        |
|                         | Percentil 75   | 16,15 por 100                         |

Los datos muestran que estos bancos destinan entre el 7,99 por 100 y el 16,15 por 100 de su presupuesto a tecnología (1), situándose la media en el 11,85 por 100. Además, se aprecia la tendencia positiva recogida a nivel mundial, ya que estos incrementaron la partida tecnológica en el último año un 4,07 por 100. El gráfico 4 muestra la relación entre el porcentaje de gasto tecnológico y la tasa de variación (en puntos básicos) del gasto tecnológico del año 2017 con respecto al año 2018. En primer lugar, se observa que todos los bancos (con una excepción) dedican al menos el 5 por 100 de su presupuesto a tecnología. En comparación con otras industrias, este umbral mínimo del 5 por 100 refleja la importancia que tiene la tecnología en la oferta de servicios bancarios.

El gráfico 4 también muestra la heterogeneidad en el gasto tecnológico. Cuando se analiza el peso del gasto tecnológico en relación a su tasa de crecimiento, parece observarse una correlación positiva. Los bancos que ya tienen integrada en su organización la importancia de la tecnología, y que actualmente invierten más que la media en ella, son los que además más han aumentado sus inversiones en tecnología en el último año. De ahí la correlación positiva que se observa en el gráfico 4.

Por su parte, el gráfico 5 recoge la relación entre el gasto tecnológico y el tamaño de la entidad. Dicho gráfico muestra cómo los bancos más pequeños (aquellos con unos activos inferiores a los 250.000 millones de dólares en activos) y los de tamaño medio (aquellos bancos con unos activos totales entre los 250.000 y los 500.000 millones



de dólares en activos) son los que destinan de media el mayor porcentaje de gasto tecnológico. Para estos dos grupos de bancos, tanto la media como la mediana se sitúan por encima del 13 por 100, mientras que para aquellos bancos que superan los 500.000 millones de dólares en activos el gasto tecnológico está por debajo del 10 por 100 (la media de toda la muestra). Este gráfico evidencia una cierta relación inversamente proporcional y no lineal entre el gasto tecnológico y el tamaño de los bancos, sugiriendo que el gasto tecnológico es más importante entre las entidades de tamaño pequeño y mediano. Aun cuando, por su mayor capacidad financiera, en términos agregados los grandes proyectos tecnológicos los protagonicen los grandes bancos.

#### IV. LAS NUEVAS TECNOLOGÍAS BANCARIAS: BIG DATA, IA, BLOCKCHAIN Y CLOUD COMPUTING

Aunque durante el proceso de transformación tecnológica del sector bancario están apareciendo muchas nuevas tecnologías que ofrecen la posibilidad de mejorar la oferta de los servi-

cios financieros, principalmente los profesionales del sector coinciden en señalar a cuatro tecnologías como las más disruptivas: *big data*, inteligencia artificial, *blockchain* y *cloud computing*. Así lo recogen algunos estudios del sector (Ernst & Young, 2018) al señalar estas tecnologías como aquellas en las que más están invirtiendo actualmente y en las que más se plantean aumentar sus inversiones en los próximos tres años. Es por ello, que su implementación se ha venido a denominar como la nueva tecnología bancaria. El potencial de estas tecnologías en la oferta de servicios financieros es muy extenso, aunque el análisis de sus actuales aplicaciones en banca determina que todas ellas están orientadas en tres ámbitos: fortalecer el posicionamiento competitivo de la entidad ante la llegada de nuevos competidores, mejorar directamente la experiencia de los clientes para ampliar la capacidad de atraer a nuevos clientes y de retener a los actuales y ahorrar en costes para mejorar la eficiencia operativa.

##### 1. Big data


Las entidades bancarias manejan de media alrededor de

1,9 *petabytes* (1.900 *terabytes*). El sector bancario en su proceso de transformación tecnológica está trabajando arduamente para adoptar un enfoque totalmente basado en el análisis masivo de datos con el objetivo de ofrecer mejores servicios a sus clientes. Gran parte del sector ya ha incorporado el análisis de datos en la gestión de su información. Actualmente, los principales retos que se plantea en el uso del *big data* se centran en la mejora de la experiencia del cliente, la optimización en la gestión de riesgos mediante una mejor evaluación del riesgo crediticia y la gestión de la información financiera que permita segmentar mejor los clientes.

- *Experiencia de cliente*: el perfilado del cliente mediante el uso de una gran cantidad de datos no estructurados se emplea para analizar patrones de comportamiento. El vínculo existente entre la experiencia positiva del cliente y la retención de clientes, ofrece la oportunidad al *big data* de reducir la elevada tasa de intención de cambio de entidad, cerca del 50 por 100. Por su parte, los consumidores parecen dispuestos a compartir sus datos con las entidades financieras. Un estudio recoge que solo el 17 por 100 de los consumidores no están dispuestos a compartir datos, al contrario que la mayoría que estaría dispuesta a compartir datos personales a cambio de mejores condiciones que redunden en una mejor experiencia como usuario.

- *Evaluación crediticia*: comprender los patrones de gasto y el historial crediticio de un cliente puede ayu-

GRÁFICO 5  
GASTO TECNOLÓGICO POR TAMAÑO DE LA ENTIDAD BANCARIA



Fuente: Elaboración propia.

dar a evaluar rápidamente los riesgos de conceder un préstamo. Se estima que la predicción de impagos basada en el *big data* mejora el porcentaje de predicciones correctas alcanzándose un 85 por 100, lo que supondría un ahorro de entre el 6 por 100 y el 25 por 100 de las pérdidas totales.

- *Segmentación de clientes:* el uso de técnicas algorítmicas para el tratamiento de datos permite que la entidad bancaria pueda comprender mejor las necesidades de sus clientes, identificar problemas en la orientación de su producto y encontrar la mejor manera de solucionar los problemas existentes. Además, la incorporación de información no financiera para su análisis también se revela como esencial para adaptar y ofrecer productos financieros que se ajusten a las necesidades de cada cliente. Se estima que el uso de datos para tomar mejores decisiones de mercadotecnia puede aumentar la productividad de la misma entre un 15 por 100 y 20 por 100 al ofrecer productos más personalizados.

## 2. Inteligencia artificial

Se estima que las herramientas habilitadas para la inteligencia artificial generarán 2.900 millones de dólares a las empresas en 2021. Especialmente relevante es el impacto para las entidades financieras que, en un horizonte de diez años, podrían reducir un 22 por 100 los costes gracias al uso de la inteligencia artificial (Autonomous NEXT, 2019). Se prevé que a medida que los procesos y tareas se di-

gitalicen, el abanico de usos de la inteligencia artificial crecerá. Actualmente, a pesar de las posibles aplicaciones de la inteligencia artificial, su uso en la industria bancaria queda reducido a un conjunto de actividades.

- *Asistentes personales:* la inteligencia artificial ya es una realidad en lo que respecta a los asistentes personales. Los bancos están utilizando *chatbots* y asistentes de voz para interactuar con los clientes y resolver sus dudas y problemas. El desarrollo tecnológico hace que la experiencia para el usuario haya mejorado. Para los clientes es cada vez más difícil saber si están hablando con un humano o con un robot. A su vez se constata una creciente aceptación de estos asistentes personales por parte de la demanda, gracias a la difusión de los asistentes de voz implementados por las *bigtech* (Alexa en Amazon, Siri en Apple o Cortana en Microsoft). Un 58 por 100 de los consumidores usan la voz para realizar las tareas que alguna vez realizaron escribiendo o mediante la pantalla táctil. Recientes estudios muestran que hasta un 44 por 100 de los clientes bancarios estarían dispuestos a permitir que un asistente de voz tuviera acceso a la información personal asociada a su cuenta bancaria. Los asistentes digitales habilitados para voz presentan un amplio potencial en la industria de servicios financieros, desde consultas hasta la asistencia inteligente para asesoría (*voice-advisory*). Sin embargo, el uso que tal vez se desarrolle en mayor medida es el de los pagos por voz. Algunas instituciones financieras ya se han

posicionado al respecto, al permitir la realización de operaciones bancarias mediante voz. Las estrategias empleadas son bastante diversas. Algunas han utilizado asistentes ya desarrollados por las *bigtech*, como es el caso de Capital One, American Express y US Bank, que tienen sus funcionalidades en Alexa. O de Barclays y el Royal Bank of Canada, que se han integrado con Siri. Otros como el Banco Santander, Bank of America o Wells Fargo han optado por habilitar sus propios asistentes de voz en sus aplicaciones móviles.

- *Automatización de decisiones:* otro de los usos de la inteligencia artificial se centra en la ejecución de actividades de poco valor añadido que, por tanto, pueden ser automatizadas. Muchos bancos están empleando esta tecnología para la ejecución de transacciones periódicas y que, en última instancia, siempre puedan ser revisadas, si es preciso, por humanos. La automatización de estas actividades, bajo la correspondiente supervisión, prevé generar un ahorro de recursos para las entidades bancarias.
- *Cumplimiento normativo:* la inteligencia artificial también se está empleando para detectar anomalías en transacciones que podrían indicar fraude o blanqueo de dinero. La carga que supone para las entidades financieras cumplir con la cada vez más extensa normativa bancaria hace que la combinación de la inteligencia artificial con el *regtech* alivie y simplifique una parte importante de dicha carga. Por el momento, se estima

que el uso de estas nuevas tecnologías en el cumplimiento normativo contra el fraude puede suponer un ahorro de 4.600 millones de dólares para el sector financiero (Quilan & Associates, 2016).

### 3. Blockchain

El potencial de esta tecnología de registro descentralizado es muy amplio en todas las industrias, pero especialmente en la bancaria donde algunos estudios establecen que el ahorro anual por su uso puede llegar al 30 por 100 (Accenture, 2017). Su potencial impacto hace que las inversiones de la industria en *blockchain* se estén acelerando. En este caso, dada las características de esta tecnología sus usos principales están ligados al desarrollo de redes o consorcios formados por varias entidades bancarias. Actualmente, sus usos se han centrado en tres ámbitos principalmente.

- *Pagos transfronterizos*: el principal reto que la tecnología *blockchain* pretende conseguir es hacer que las transacciones entre entidades se realicen más rápido y con un mayor nivel de seguridad. Con el uso de la tecnología *blockchain* es posible que cada transacción quede registrada en múltiples nodos de una red que estaría formada por un conjunto de bancos miembros. Así, tanto el banco remitente como el banco destinatario pueden saber exactamente y de forma segura dónde se encuentra el dinero. Además de acortar el tiempo de ejecución, se estima que estas redes de bloques pueden reducir el coste de las transacciones al 2 por 100

manteniéndose un alto nivel de seguridad. Este potencial está propiciando el nacimiento de iniciativas globales para liderar el uso del *blockchain* en las transferencias internacionales.

- *Cumplimiento normativo*: el uso del *blockchain* permite que los datos de cada transacción se dispersen en varios bloques de la red *blockchain* garantizando que nadie pueda manipular los datos. Con la tecnología de registro distribuido, el banco puede almacenar la base de datos de transacciones codificadas para posteriormente comprobar que cada transacción tiene su contrapartida correspondiente.
- *Gestión contractual*: el uso del *blockchain*, mediante los contratos inteligentes (*smart contracts*), permite el mantenimiento de registros y transacciones relativos a los contratos. El uso de estos contratos inteligentes en transacciones comerciales acelera y simplifica los procesos, garantizando la transferencia precisa de información y haciendo cumplir las obligaciones de todas las partes. Se estima que la reducción de los costes de procesamiento que brindan los contratos inteligentes podría ahorrar a los bancos entre 3.000 y 11.000 millones de dólares anuales (Capgemini, 2016). Por el momento, los bancos están empleando estos contratos inteligentes para suscribir hipotecas digitales (HSBC), para comercializar algunos derivados financieros como los *swaps* (Barclays) o para otorgar préstamos sindicados internacionalmente (BBVA).

### 4. Cloud computing

Aunque actualmente más del 90 por 100 de las empresas a escala mundial declaran ser usuarias de la nube como parte de su negocio (Right Scale, 2017), la industria de servicios financieros es la que reporta el mayor grado de adopción. En total, hasta un 16 por 100 del gasto a nivel mundial de computación en la nube corresponde al sector financiero (IBM, 2017). En 2019 se estima que el volumen de inversión de la banca en este tipo de tecnologías en la nube (IDC) se sitúe alrededor de los 115.000 millones de dólares. Principalmente el uso de la nube en banca se focaliza en los siguientes ámbitos:

- *Gestión de los datos y seguridad*: la digitalización de los servicios permitirá a los bancos e instituciones financieras construir una infraestructura para brindar el mejor y adecuado servicio a los clientes. Además, frente a los ataques informáticos la autenticación de los centros de datos a través de la computación en la nube permite que todos los datos almacenados gocen de un nivel superior de seguridad. El fin es que la computación en la nube aumente la eficiencia y la seguridad en la industria financiera.
- *Experiencia de cliente*: la computación en nube permite una mejor velocidad y un mejor servicio para los usuarios permitiendo el acceso remoto de la información por parte de los clientes. Así, aquellos usuarios que acceden a su información bancaria a través de cualquier canal digital pueden experimentar una mejor experiencia de

CUADRO N.º 2  
LAS NUEVAS TECNOLOGÍAS BANCARIAS

|                                               | BIGDATA                                                                                                                                    | INTELIGENCIA ARTIFICIAL                                                                                                                                                                                                               | BLOCKCHAIN                                                                                                                                                        | CLOUD COMPUTING                                                                                                                                                                      |
|-----------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| ¿Qué es?                                      | Tecnología que permite el tratamiento masivo de grandes volúmenes de datos, tanto estructurados como no estructurados.                     | Tecnología que permite el uso de técnicas cognitivas, como los procesadores de lenguaje natural y algoritmos avanzados para analizar textos e identificar sentimientos y otro tipo de información a partir de datos no estructurados. | Tecnología que estructura de datos/información en una cadena de bloques convirtiéndose en un registro único, consensado y distribuido en varios nodos de una red. | Tecnología que permite la configuración de servidores e infraestructuras informáticas permitiendo acceder a los recursos de estos servidores desde una red, principalmente Internet. |
| Usos en el sector bancario                    | <ul style="list-style-type: none"> <li>Experiencia del cliente</li> <li>Evaluación crediticia</li> <li>Segmentación de clientes</li> </ul> | <ul style="list-style-type: none"> <li>Asistentes personales</li> <li>Automatización de decisiones</li> <li>Cumplimiento normativo</li> </ul>                                                                                         | <ul style="list-style-type: none"> <li>Pagos transfronterizos</li> <li>Cumplimiento normativo</li> <li>Gestión contractual</li> </ul>                             | <ul style="list-style-type: none"> <li>Gestión de los datos y seguridad</li> <li>Experiencia del cliente</li> </ul>                                                                  |
| Grado de adopción en el sector bancario       | Medio-alto                                                                                                                                 | Medio                                                                                                                                                                                                                                 | Incipiente                                                                                                                                                        | Alto                                                                                                                                                                                 |
| Principal medio para incorporar la tecnología | Desarrollo interno                                                                                                                         | Compra de la tecnología                                                                                                                                                                                                               | Alianzas estratégicas                                                                                                                                             | Compra de la tecnología                                                                                                                                                              |

Fuente: EY Global Banking Outlook y elaboración propia.

usuario basada en la rapidez en el acceso a la información y en una menor vulnerabilidad de su información financiera. Muchos bancos están ubicando sus pasarelas de pago, billeteras digitales, servicios para la transferencia de fondos y pagos en línea en la nube en lugar de en los servidores privados.

## V. APLICACIONES, ADOPCIÓN E IMPACTO DE LAS NUEVAS TECNOLOGÍAS BANCARIAS EN LA BANCA EUROPEA

### 1. Aplicaciones en la banca europea: proyectos globales

Una parte mayoritaria de la banca europea está realizando importantes inversiones en nuevas tecnologías bancarias. Cerca del 25 por 100 del gasto total tecnológico corresponde a estas

nuevas tecnologías. Una parte importante de estas inversiones las llevan a cabo las entidades individualmente, ya sea a través de la adquisición de la tecnología o mediante el establecimiento de alianzas estratégicas con socios tecnológicos o empresas *fintech*. Si bien en el uso de las nuevas tecnologías la escalabilidad es vital para su desarrollo, de ahí que hayan surgido en el seno de la banca europea algunos proyectos globales que unen a una parte importante del sistema bancario europeo con el objeto de poder desarrollar y mejorar algunas de estas tecnologías. Dentro de estos proyectos globales liderados por la banca europea destacan:

– *We.trade*: se trata de una plataforma innovadora de *blockchain* desarrollada por un consorcio de doce bancos europeos –CaixaBank, Deutsche Bank, Eurobank, Erste Bank, HSBS, KBC, Nordea, Rabobank, Santander, Socie-

te Generale, UBS y Unicredit– que tiene como objetivo crear un entorno comercial transparente, seguro y simplificado para empresas y bancos. Dicha plataforma utiliza la tecnología *blockchain* haciendo uso de los *smart contracts* para que las empresas puedan cerrar pedidos, establecer las condiciones de la operación y acceder a los servicios financieros ofrecidos en un entorno seguro, con una elevada trazabilidad y con rapidez.

– *Interbank Information Network (IIN)*: el objetivo de dicha red, liderada por JP-Morgan, es usar el *blockchain* para minimizar las fricciones en el proceso de pagos transfronterizos permitiendo que los pagos lleguen a los beneficiarios más rápido y con menos pasos. Dicha red permite a los bancos miembros intercambiar información bancaria en tiempo real como



una forma de verificar que se haya aprobado un pago. Hasta el momento es la red global basada en *blockchain* más extensa, con más de 200 bancos miembros, de ellos 41 europeos, y con más de 300.000 transacciones diarias.

- *Marco Polo*: se trata de un proyecto liderado por un consorcio de bancos para lanzar al mercado una plataforma de financiación comercial de cuenta abierta que usa la tecnología *blockchain* R3. El objetivo es utilizar *blockchain* para simplificar y acelerar los procesos detrás de los servicios de financiación comercial de cuentas abiertas a lo largo del ciclo comercial. La red, que actualmente cuenta con diecisiete bancos miembros, se ha expandido rápidamente y hoy es una de las más grandes en el área de financiamiento comercial.

- *Komgo*: es una plataforma que emplea la tecnología *blockchain* para financiar la comercialización de materias primas, desde petróleo hasta trigo. El uso de esta tecnología permite que múltiples partes participen entre sí de manera transparente y segura en una red compartida. Los participantes de la red se benefician de la optimización integral de la industria, reduciendo el tiempo y los costes necesarios para administrar la financiación de operaciones con materias primas. La red está formada por grandes bancos europeos como ABN Amro, BNP Paribas, Crédit Agricole, ING, Natixis, Rabobank y Société Générale.

- *Trade Information Network*: se trata de una red de información comercial digital en la nube. El objetivo de la red es abordar la demanda insatisfecha de financiación en el comienzo de la cadena de suministro. La tecnología de la nube permite que empresas y entidades bancarias puedan intercambiar de forma fácil y segura información comercial. El uso de la nube permite que las empresas lancen y verifiquen órdenes de compra y facturas con el fin de solicitar financiación comercial de los bancos que elijan y que los bancos evalúen mejor los riesgos de las empresas. Esta red está integrada por ANZ, BNP Paribas, Citi, Deutsche Bank, HSBC, Santander y Standard Chartered.

A nivel nacional también encontramos otros proyectos. En España destacan Niuron y Alastria. El consorcio bancario Niuron, liderado por Cecabank, e integrado por otras ocho entidades españolas, desarrolla una plataforma basada en *blockchain* para mejorar las verificaciones de la identidad digital de un cliente con su consentimiento. Alastria, por su parte, surge como la primera plataforma tecnológica multisectorial del mundo basada en *blockchain* y tecnologías de registros descentralizadas. Su objetivo, entre otros, es desarrollar nuevos sistemas y servicios para que, por ejemplo y entre otras cosas, cualquier persona o empresa en España pueda identificarse digitalmente de forma segura. Algunas de las principales compañías españolas forman parte de esta red que integra a un total de cuarenta entidades bancarias.

## 2. Adopción e impacto en la banca europea: análisis lexicográfico

Para examinar el grado de adopción de la nueva tecnología bancaria por parte de los principales bancos europeos, y ante la escasez de datos desagregados a nivel de entidad bancaria, analizamos la relevancia de su adopción por la actual banca europea partiendo de un análisis textual o lexicográfico. Con este objetivo se analizan las referencias terminológicas a las nuevas tecnologías –*big data*, inteligencia artificial, *blockchain* y *cloud computing*– que se hacen a las cuentas anuales que publican los bancos. El examen de las cuentas anuales (2) permite conocer el grado de adopción de estas tecnologías en la medida en que las entidades bancarias incluyen una descripción del negocio, riesgo, factores, principales iniciativas comerciales, operaciones y estados financieros.

Para analizar dicha adopción en la banca europea, la muestra se compone de todos aquellos bancos europeos que son objeto de los test de estrés por parte del Banco Central Europeo, un total de 48 entidades bancarias. Al centrarnos en este grupo de entidades, garantizamos que estamos analizando la adopción de las nuevas tecnologías por parte de aquellos bancos más significativos del sistema bancario europeo al aglutinar la mayor parte de los clientes bancarios.

Como parte de este análisis lexicográfico identificamos un conjunto de palabras claves que hacen referencia a las nuevas tecnologías bancarias identificadas (3). Para ser consistentes con el objeto de estudio, el análisis



sis textual se circunscribe a aquellas referencias que hacen las entidades financieras en cuanto al uso de dichas nuevas tecnologías. Todas aquellas referencias genéricas en las cuentas anuales que se hacen a las nuevas tecnologías bancarias pero que no tienen que ver con la adopción de las mismas no son consideradas. Con ello, nos aseguramos que dicho análisis textual recoge la adopción, uso actual o intención de implementar estas nuevas tecnologías por parte de la banca europea.

Dicho análisis revela como resultado que el 94 por 100 de los bancos europeos hacen referencia al uso de al menos una de estas tecnologías en sus cuentas anuales (gráfico 6). Este resultado viene a confirmar el elevado grado de adopción de las nuevas tecnologías bancarias en el sector bancario europeo. Además, el gráfico recoge que el porcentaje más elevado se corresponde con el uso del *big data*, seguido de la inteligencia artificial y *blockchain*. Es reseñable el menor impacto que parece tener la tecnología de la computación en la nube, pues sólo un 42 por 100 de las entidades bancarias hacen referencia a su adopción. La mayor adopción del *big data*, en comparación con las demás tecnologías identificadas, se explica en parte por las menores inversiones que requiere su implementación. El uso de técnicas algorítmicas y/o de *machine learning* para el llevar a cabo un mejor análisis de los datos son más fácilmente implementables en el seno de una entidad bancaria. Si bien, la incorporación de inteligencia artificial, *blockchain* y la computación en la nube requiere inversiones previas en el establecimiento de una infraestructura tecnológica.


Posteriormente, a partir del análisis lexicográfico de la adopción y uso de las nuevas tecnologías bancarias, clasificamos a las entidades bancarias en función de la intensidad del uso que hacen de las nuevas tecnologías. Como el gráfico 6 revela, una parte significativa de la banca europea hace uso de las nuevas tecnologías bancarias; por ello, para profundizar en el posible impacto que puede tener la adopción de estas tecnologías nos centramos en los dos grupos de bancos que se sitúan en los extremos en lo que respecta a la implementación de estas nuevas tecnologías. Identificamos dos grupos de entidades bancarias: aquellas que hacen un uso intensivo de estas tecnologías (bancos líderes en la nueva tecnología bancaria); y aquellas que hacen un uso limitado de las mismas (bancos incipientes en el uso de nueva tecnología bancaria). A partir de los resultados obtenidos por el análisis textual, clasificamos como bancos líderes en la nueva tecnología bancaria a

aquellos bancos que se sitúan por encima del percentil 75 en lo que se refiere al uso de las nuevas tecnologías, según se infiere de sus cuentas anuales. Mientras que aquellos bancos que se sitúan por debajo del percentil 25 son clasificados como bancos incipientes en su uso. El resto de entidades bancarias se asume que hacen un uso normal, en la media, de estas nuevas tecnologías bancarias. Finalmente, con el objeto de examinar las diferencias entre estos dos grupos de entidades obtenemos información financiera de estas entidades mediante Orbis BankFocus. Para ello se obtienen los valores medios de algunos de los más relevantes indicadores financieros –tamaño, rentabilidad, ingresos y eficiencia– y se realizan test de t-Student para comparar las medias de estos dos grupos de bancos con el objetivo de determinar si la diferencia entre los grupos es estadísticamente significativa.

Como se recoge en el cuadro n.º 3, existen diferencias entre

GRÁFICO 6

**PORCENTAJE DE BANCOS DE LA MUESTRA QUE HAN ADOPTADO LAS NUEVAS TECNOLOGÍAS BANCARIAS (PORCENTAJE)**



aquellos bancos considerados como bancos incipientes y aquellos que ya han adoptado las nuevas tecnologías bancarias y que son considerados como bancos líderes en su uso. A raíz de los resultados del cuadro, se observa que los bancos que hacen un mayor uso de la nueva tecnología bancaria tienen un mayor volumen de activos y mayores beneficios en términos absolutos. Este resultado sugiere que los bancos que más muestran un mayor grado de adopción de las nuevas tecnologías bancarias son los bancos de mayor tamaño. Respecto a los resultados de la prueba *t*-Student para contrastar la igualdad de medias, los bancos más tecnológicos, con un mayor grado de adopción de las nuevas tecnologías bancarias, son capaces de generar más ingresos en relación a su nivel de activos. Este resultado parece indicar que la adopción de estas nuevas tecnologías bancarias no solo tiene incidencia en la estructura de costes de la entidad, sino que también puede tenerla en las fuentes de generación de ingresos. En este sentido, ya existen algunos estudios que muestran el impacto positivo de la adopción tecnológica por parte de la banca en la retención de los clientes y en la generación de ingresos (Campbell y Frei, 2010; Xue et al., 2011). Este resultado también se complementa con los relativos a la rentabilidad. Como se muestra en el cuadro n.º 3, la banca líder en la adopción de tecnologías presenta de media un mayor rentabilidad por activo (ROA) y por patrimonio neto (ROE) que la banca denominada menos tecnológica. Además, dicha diferencia es estadísticamente significativa en el caso del ROA, es decir, que los bancos que han adoptado en mayor grado las nuevas tecnologías

CUADRO N.º 3

**DIFERENCIAS ENTRE ENTIDADES FINANCIERAS EN FUNCIÓN DEL GRADO DE ADOPCIÓN DE LA NUEVA TECNOLOGÍA BANCARIA**

|                                    | BANCA MENOS<br>TECNOLÓGICA<br>(INCIPIENTES) | BANCA MÁS<br>TECNOLÓGICA<br>(LÍDERES) | T-TEST<br>(P-VALOR) |
|------------------------------------|---------------------------------------------|---------------------------------------|---------------------|
| Activos (miles de dólares)         | 276,29                                      | 874,64                                | 0,0059              |
| Beneficios (miles de dólares)      | 876,26                                      | 3292,42                               | 0,0204              |
| Ingresos operacionales/activos (%) | 1,65%                                       | 2,32%                                 | 0,0373              |
| ROA                                | 0,4273                                      | 0,5641                                | 0,0801              |
| ROE                                | 2,07                                        | 7,90                                  | 0,1254              |
| Ratio de eficiencia                | 66,44                                       | 63,30                                 | 0,6519              |
| Variación gasto tecnológico (p.b)  | 0,68                                        | 0,50                                  | 0,3978              |
| <i>n</i>                           | 12                                          | 12                                    |                     |

bancarias presentan una mayor rentabilidad respecto al resto de entidades bancarias europeas. Aunque a partir de dicho resultado no puede inferirse causalidad, sí parece aportar evidencias a favor de una cierta correlación positiva entre la adopción de las nuevas tecnologías y la rentabilidad bancaria. En lo que respecta a la eficiencia, aunque los bancos digitales presentan una mejor ratio de eficiencia, las diferencias entre ambos grupos de entidades no son estadísticamente distintas. Por último, se aprecia que la banca menos tecnológica ha crecido más de media su gasto tecnológico en el último año. Dicho resultado puede explicarse por la necesidad de estos bancos de adaptarse al cambio tecnológico para no perder en competitividad respecto al resto de sus competidores bancarios europeos.

## VI. CONCLUSIONES

En un contexto cada vez más digital, la adopción e implementación de nuevas tecnologías en la industria bancaria es clave para mejorar la experiencia del cliente en la prestación de servicios financieros al tiempo que se refuerza la seguridad. De ahí

que, en relación a otras industrias, el sector bancario lidere el gasto tecnológico. La evidencia muestra que dicho proceso de cambio tecnológico en la industria bancaria es susceptible de acelerarse. Se espera una mayor relevancia del gasto tecnológico en los presupuestos de las entidades bancarias, de manera que las tasas de crecimiento de los próximos años superen a las actuales.

Aunque cualquier cambio tecnológico se caracteriza por su dinamismo, en el sector bancario han surgido algunas tecnologías que por su elevado potencial transformador empiezan a configurar una «nueva tecnología bancaria». Entre esta nueva tecnología bancaria se identifican el análisis masivo de datos (*big data*), la inteligencia artificial (IA), la tecnología de registro descentralizado (*blockchain*) y la computación en la nube (*cloud computing*). La implementación de estas tecnologías es susceptible de tener un impacto en la actividad bancaria mayor que el de anteriores tecnologías. Tanto a nivel individual como a través de proyectos conjuntos, las entidades bancarias a nivel mundial comienzan a implementar dichas tecnologías en su seno.

El presente artículo examina la evolución del gasto tecnológico de las entidades bancarias, el grado de adopción de la llamada «nueva tecnología bancaria» y el impacto de dicha tecnologías en las entidades financieras. El análisis del gasto tecnológico evidencia que dicho proceso de transformación tecnológica de la industria bancaria es global, estando, a su vez, sometido a una continuada aceleración. Se observa que aquellos bancos que actualmente más invierten en tecnología son los que además más aumentan sus inversiones en tecnología. Además, una parte importante de dicho gasto tecnológico se concentra en las tecnologías integrantes de la «nueva tecnología bancaria». Actualmente las entidades bancarias emplean la «nueva tecnología bancaria» para fortalecer su posicionamiento competitivo, mejorar directamente la experiencia de sus clientes y mejorar su eficiencia operativa. Este esfuerzo tecnológico del sector se está produciendo tanto individualmente, donde cada entidad decide y ejecuta su presupuesto tecnológico de acuerdo con sus prioridades, como a través de proyectos globales, en los que participan un conjunto de entidades bancarias. El interés de acometer esfuerzos conjuntos reside en el hecho de que las entidades puedan afrontar retos tecnológicos superiores a los que podrían desarrollar por separado.

Por último, el artículo pone de relieve la existencia de diferencias entre las entidades bancarias en función del grado en que han adoptado la nueva tecnología bancaria. Aunque no puede inferirse una relación de causalidad, sí parecen existir evidencias a favor de una cierta correlación positiva entre la adopción de las

nuevas tecnologías, la rentabilidad bancaria y la capacidad de generar ingresos.

#### NOTAS

(1) La ratio de gasto tecnológico se obtiene como el total del gasto dedicado en tecnología por la entidad bancaria en relación a sus gastos operacionales.

(2) Para ser consistentes en el análisis lexicográfico se analizan las cuentas anuales en su versión inglesa.

(3) Los términos utilizados en el análisis lexicográfico son: *artificial intelligence* y *IA* (relativos a la tecnología de la inteligencia artificial), *big data*, *data analytics* y *data analysis* (relativos a la tecnología de *big data*), *cloud* y *cloud computing* (relativos a la tecnología de computación en la nube), *blockchain*, *DLT* y *distributed ledger technology* (relativos a la tecnología).

#### BIBLIOGRAFÍA

- ACCENTURE (2017). *Banking blockchain. A value analysis for Investment Banks*.
- BECCALLI, E. (2007). Does IT investment improve bank performance? Evidence from Europe. *Journal of Banking & Finance*, 31, pp. 2205-2230.
- BERGER, A. N. (2003). The Economic Effects of Technological Progress: Evidence from the Banking Industry. *Journal of Money, Credit, and Banking*, 35(2), pp. 141-176.
- CAMPBELL, D. y FREI, F. (2010). Cost Structure, Customer Profitability, and Retention Implications of Self-Service Distribution Channels: Evidence from Customer Behavior in an Online Banking Channel. *Management Science*, 56(1), pp. 4-24.
- CAPGEMINI (2016). *Smart Contracts in Financial Services: Getting from Hype to Reality*.
- CARBÓ-VALVERDE, S., CUADROS-SOLAS, P. J. y RODRÍGUEZ-FERNÁNDEZ, F. (2020). The effect of banks' IT investments on the digitalization of their customers. *Global Policy* (forthcoming).

CASOLARO, L. y GOBBI, G. (2007). Information Technology and Productivity Changes in the Banking Industry. *Economics Notes*, 36(1), pp. 43-76.

CHOWDHURY, A. (2003). Information Technology and Productivity Payoff in the Banking Industry: Evidence from the Emerging Markets. *Journal of International Development*, 15, pp. 693-708.

COMPUTER ECONOMICS (2019). *IT Spending & Staffing Benchmarks 2018/2019*.

DEYOUNG, R., LANG, W. W. y NOLLE, D. L. (2007). How the Internet affects output and performance at community banks. *Journal of Banking & Finance*, 31, pp. 1033-1060.

ERNST & YOUNG (2018). *Global Banking Outlook 2018*. Ernst & Young Global Limited, pp. 1-19.

HAYNES, M. y THOMPSON, S. (2000). The productivity impact of IT deployment: An empirical evaluation of ATM introduction. *Oxford Bulletin of Economics and Statistics*, 62(5), pp. 607-619.

HE, Z. (2015). Rivalry, Market Structure and Innovation: The Case of Mobile Banking. *Review of Industrial Organization*, 47(2), pp. 219-242.

HERNÁNDEZ-MURILLO, R., LLOBET, G. y FUENTES, R. (2010). Strategic online banking adoption. *Journal of Banking and Finance*, 34(7), pp. 1650-1663.

HERNANDO, I. y NIETO, M. J. (2007). Is the Internet delivery channel changing banks' performance? The case of Spanish banks. *Journal of Banking and Finance*, 31(4), pp. 1083-1099.

IBM (2017). *Tailoring hybrid cloud for banking*.

IDC (2018). *Pivot Table: Worldwide IT Spending 2016 – 2021 – Worldwide Banking IT Spending Guide, Version 2, CY 2Q18*.

KOZAK, S. (2005). The role of information technology in the profit and cost efficiency improvements of the

|                                                                                                                                                                                                                                                                                                                                                                                                                                                       |                                                                                                                                                                                                                                                                                                                                                                                                                                              |                                                                                                                                                                                                                                                                                                                                                                                                       |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <p>banking sector. <i>Journal of Academy of Business and Economics</i>, 5(2) February.</p> <p>MARKUS, M. L. y SOH, W. L. C. (1993). Banking on information technology: converting IT spending into firm performance. En M. A. BANKER, R. KAUFMANN, R. J. MAHOOD (eds.), <i>Strategic information technology management: perspectives on organizational growth and competitive advantage</i>, pp. 375-403. Harrisburg, PA.: Idea Group Publishing.</p> | <p>AUTONOMOUS NEXT (2019). <i>Augmented Finance &amp; Machine Intelligence</i>.</p> <p>QUILAN &amp; ASSOCIATES (2016). <i>From KYC to TYT. Blockchain's emerging role in the global payments system</i>.</p> <p>RIGHT SCALE (2017). <i>State of the Cloud Report</i>.</p> <p>SCOTT, S. V, REENEN, J. VAN y ZACHARIADIS, M. (2017). The long-term effect of digital innovation on bank performance : An empirical study of SWIFT adoption</p> | <p>in financial services. <i>Research Policy</i>, 46(5), pp. 984-1004.</p> <p>STIGLITZ, J. (2017). The Revolution of Information Economics: The Past and the Future. National Bureau of Economic Research. <i>Working Paper</i>, n.º 23780.</p> <p>XUE, M., HITT, L. M. y CHEN, P. (2011). Determinants and Outcomes of Internet Banking Adoption. <i>Management Science</i>, 57(2), pp. 291-307.</p> |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|

## Resumen

En la última década se han desarrollado tecnologías de tratamiento descentralizado de la información que proporcionan notables mejoras de eficiencia en cuanto a coste y velocidad. La aplicación de estas innovaciones al sector financiero se ha denominado de forma genérica como finanzas descentralizadas (*decentralized finance* o *DeFi*). En este artículo se trata de explicar las principales ventajas que puede incorporar la aplicación de sistemas *DeFi* al mundo financiero y bancario, así como los retos que impone el tratamiento descentralizado de la información para supervisores y reguladores. Se describe, asimismo, la diferencia entre el grado de descentralización limitado que ofrecen el llamado *open banking* y la descentralización cuasicompleta que proponen las *DeFi*.

*Palabras clave:* finanzas descentralizadas, *fintech*, *blockchain*, *open banking*.

## Abstract

A number of decentralized information technologies have emerged over the last decade to offer speed and cost efficiency gains. The application of these innovations in the financial sector has been labelled as decentralized finance (DeFi). This article attempts to explain the main advantages of applying DeFi to banking and other financial services as well as the regulatory and supervision channels related to the decentralized treatment of information. The differences between the limited decentralization of the so-called open banking and the quasi-complete decentralization of DeFi alternatives are also discussed.

*Keywords:* decentralized finance, *fintech*, *blockchain*, *open banking*.

*JEL classification:* G21, O30.

# UNA APROXIMACIÓN A LAS FINANZAS DESCENTRALIZADAS

Jesús PÉREZ

Digital Assets Institute (\*)

## I. INTRODUCCIÓN: TECNOLOGÍA, FINTECH Y BLOCKCHAIN

EL sector financiero ha asistido durante estas últimas décadas a cambios tecnológicos que han tenido un impacto muy relevante en su eficiencia y en la forma de entender la distribución de productos financieros. El término *fintech* (*finance & technology*) ha emergido como un concepto que viene a describir cómo el sector se ha reinventado desde la base de la tecnología para concebir una nueva forma de entender cómo ofrecer servicios financieros. Lo cual ha permitido profundizar en la digitalización de todos los procesos y la tendencia hacia un coste cero de los procesos transaccionales que históricamente requerían de un alto esfuerzo humano de cálculos y consolidaciones.

El fácil acceso a la tecnología, ha permitido acelerar la aparición de nuevos competidores que han sido capaces de conseguir desarrollar una oferta con una mayor eficiencia en costes. Esta se ha trasladado en las comisiones de los servicios a los clientes comenzando una continua captación de clientes cuyos pequeños crecimientos iniciales han hecho al sector subestimar esta amenaza. Pero estos crecimientos han seguido modelos exponenciales que ya están en estos momentos explotando como una de las principales preocupaciones actuales y siendo un debate ya continuo en los

órganos de decisión.

Estos procesos exponenciales solo pueden explicarse tanto en el sector financiero como en otros sectores como el *media*, por el importante impacto que ha tenido la hiperconexión de Internet más la usabilidad que aportaron los dispositivos móviles. Esto configura una nueva velocidad en la capacidad de impacto en la población global de nuevos productos, que están actualmente monopolizados por las grandes plataformas, como Facebook, Google, Amazon. En este contexto, el sector ya establecido (por ejemplo, la banca) se enfrenta a la diatriba de perder una de sus principales ventajas competitivas, que era la distribución de productos financieros, y que le permitía definir su margen de intermediación ante la escasa transparencia de la oferta.

La velocidad de innovación es cada vez mayor y, sin haberse consolidado totalmente *fintech*, asistimos a la creación de un nuevo paradigma de innovación que en el sector de las finanzas puede conceptualizarse como finanzas descentralizadas (*Decentralized finance*, *DeFi*) y que se construye sobre las bases de Bitcoin y *blockchain*. Estamos en una fase muy incipiente de esta revolución que supone un cambio disruptivo que viene a dar el relevo de la disrupción al fenómeno *fintech* que ha entrado en una etapa de innovación incremental. Se trata de un nuevo fenómeno de disrupción que es significativa-




mente diferente al propuesto por el fenómeno *fintech*.

En este artículo, se revisan los principios de este nuevo paradigma que se conoce como finanzas descentralizadas y cuáles son los principales argumentos y datos que sostienen que pueda considerarse una innovación disruptiva del estado actual de innovación en el sector financiero.

## II. VENTAJAS COMPETITIVAS TECNOLÓGICAS

En la historia de los avances tecnológicos es un fenómeno habitual el enfrentamiento de la sociedad o las empresas existentes. Se suele observar una oposición importante a los cambios. Así ocurrió, por ejemplo, con los artesanos ingleses en el siglo XIX, con su oposición a la mecanización de procesos productivos, un fenómeno al que se denominó ludismo. Sin embargo, la historia económica también sugiere que, a medio plazo, no es posible ignorar una tecnología superior, porque el propio mercado se encargará de seleccionar las opciones más productivas y que generen más valor. Si esta tecnología ofrece una suficiente ventaja competitiva potencial, el mercado acabará financiando las empresas que la desarrollen definiendo nuevos paradigma tecnoeconómicos (Pérez, 2010)

Es complicado no adoptar una tecnología que es objetivamente superior por la capacidad de ofrecer más productividad. Cualquier barrera artificial a estas tecnologías no podrá imponerse de forma global, siempre habrá algún participante que la desarrollará y acabará imponiéndose porque además ofrecerá una



mayor rentabilidad para el capital (gráfico 1).

Asimismo, estos nuevos paradigmas no solo tienen impacto en las empresas, sino también en el contexto institucional. Los entornos regulatorios que mejor entienden estas oportunidades son las que ofrecen un espacio para desarrollar estas nuevas empresas y una mayor ventaja competitiva. Así se refleja, hoy en día, con la concentración de gigantes tecnológicos en áreas geográficas donde la inversión en innovación y la regulación han permitido el desarrollo de estas actividades.

Estas transformaciones precisarán también de un cambio en la demanda, en la medida en que implican nuevos hábitos y herramientas que suelen ser lideradas por generaciones que nacen con estas posibilidades y no muestran resistencia a realizar esa transición. No obstante, el importante foco en la «usabilidad» (facilidad y velocidad de uso) que suelen desarrollar estas revoluciones en su fase de despliegue suele facilitar la adopción de estas nuevas propuestas.

Cualquier barrera artificial a estos nuevos paradigmas es cada vez más compleja y mayor es la dificultad de imponer regulaciones a nivel global, por la necesidad de coordinación entre países. Por tanto, imponer regulaciones específicas sin coordinación acaba por convertirse en barreras locales que protegen a corto plazo a la industria «incumbente», por lo que acabará adaptándose a esta competición con retraso.

La nueva tecnología financiera basada en la descentralización, ofrece ventajas competitivas y que están siendo o serán adoptadas por las entidades financieras, supervisores y bancos centrales.

## III. EVOLUCIÓN DE LAS FINANZAS DESCENTRALIZADAS: SISTEMA DE PROTOCOLOS

La primera implementación de las finanzas descentralizadas fue Bitcoin. Nace con el famoso artículo de Nakamoto (2008). El 12 de enero de 2009 se realiza

la primera transacción de dinero criptográfico, que se apoya en un sistema distribuido de nodos, donde una arquitectura descentralizada sustituye a la tradicional arquitectura centralizada de los sistemas financieros. La adopción de este fenómeno ha tenido uno de los mayores crecimientos de la historia del dinero.

Lo más relevante tecnológicamente es la arquitectura descentralizada que presenta Bitcoin y que se asienta en la tecnología de *blockchain*, y en un importante apoyo de agentes sin relación, que en base a incentivos financieros, ponen a disposición del proyecto infraestructura tecnológica (minado) para incrementar la seguridad de la Red. Este fenómeno consolida una red de pagos sobre la que emerge un *bitc* como activo que en diez años ha demostrado una solidez en cuanto a disponibilidad cercana al 100 por 100, y demostrando una inviolabilidad en la seguridad de sus datos. Esta primera implementación de arquitectura de protocolos financieros que se apoyan en redes descentralizadas, es el inicio de una serie de protocolos finan-

cieros que se han desarrollado especialmente desde 2017 y que vienen a conocerse como finanzas descentralizadas.

En ingeniería, cuando se habla de protocolos de comunicaciones, se hace referencia a un sistema de reglas que permiten a dos o más entidades comunicarse entre ellas para transmitir información. Internet es uno de los ejemplos más importantes del papel que juegan los protocolos en generar estos sistemas abiertos que permiten establecer redes de comunicación. Estos protocolos en Internet son del tipo, entre otros, de TCPIP, HTTP, SMTP y permiten poder acceder a páginas web o recibir correo electrónico. En general, el desarrollo tecnológico ha desarrollado protocolos simples que han permitido construir sobre ellos grandes aplicaciones. Pero *blockchain*, como tecnología, ha propuesto construir protocolos más complejos que permiten sobre los que pueden construirse aplicaciones mucho más sencillas o ligeras (véase Monegro, 2016: gráfico 2).

Bajo este prisma protocolario tecnológico, Bitcoin puede en-


tenderse como el «protocolo de dinero». De tal forma que, para poder utilizar una infraestructura para usar dinero, ya no es necesario apoyarse en la infraestructura tradicional financiera, sino que podemos valernos de este protocolo.

*El desarrollo de estos protocolos financieros han emergido durante 2018 y 2019, desarrollando una completa nueva infraestructura financiera. ethereum es la plataforma que está liderando estos desarrollos por su capacidad de programación. Estos protocolos actualmente dan acceso financiero a cualquier actor que tenga conexión a Internet, consolidando una infraestructura global.*

#### IV. DIFERENCIA ENTRE FINANZAS DESCENTRALIZADAS Y OPEN FINANCE

La relación entre eficiencia y grado de descentralización de las arquitecturas anteriormente descritas es una de las grandes discusiones de la comunidad de *blockchain*. La cuestión práctica es hasta qué punto estas arquitecturas pueden apoyarse para todas su funcionalidades en soluciones totalmente descentralizadas. En este sentido, es necesario revisar, tanto desde un punto de vista tecnológico como desde un punto de vista de gobernanza del proyecto, el nivel de centralización que presentan. Existen proyectos que, aunque pueden presentar arquitecturas tecnológicas descentralizadas en su diseño, cuentan con una gobernanza centralizada en sus fundadores que son los que toman las decisiones. Cuando nos encontramos con proyectos totalmente descentralizados po-

GRÁFICO 2  
PROTOCOLOS DE LA WORLD WIDE WEB Y DE BLOCKCHAIN



Fuente: Monegro (2016).

demos hablar de un concepto de nueva generación que son las organizaciones autónomas descentralizadas o *DAO* (*decentralized autonomous organization*). Se trata de organizaciones o empresas que desarrollan su actividad mediante una serie de reglas programadas y descentralizadas. Bitcoin es el caso más puro de descentralización y puede considerarse el primer ejemplo de *DAO*. Se trata de una empresa que proporciona servicios de pago o almacenamiento de valor por lo que cobra comisiones que reparte entre los «mineros», que son los empleados que mantienen la seguridad de la red. En ese sentido –y aunque se trata de un campo donde las definiciones todavía no se han acabado de estandarizar– el término *open finance* engloba todo los protocolos/organizaciones financieras que se desarrollan en arquitecturas descentralizadas y que permiten un acceso universal (humano o automático) que esté conectado a Internet. Todo ello con independencia de la organización corporativa. Sin embargo, el término finanzas descentralizadas hace más énfasis adicional en el hecho que toda su arquitectura sea descentralizada, es decir que no exista un control de estos protocolos por ningún sistema que dependa de un elemento central, incluida también la gobernanza de estos proyectos.

Existen diferentes ventajas competitivas de desarrollar o apoyarse en soluciones financieras que se basan en estas arquitecturas descentralizadas cuya tecnología que subyace es *blockchain* y cuyos ejemplos prácticos más conocidos son diferentes sistemas de criptodinero como Bitcoin:

*Nivel de seguridad*: la premisa en este punto es que la tecnología es solo un habilitador de la seguridad, pero que lo que marca este nivel de seguridad en sentido último son otros factores técnicos como:

- *Capacidad de cómputo de la red*: el algoritmo de consenso (el conocido *proof of work*) define una serie de incentivos económicos para que puedan poner capacidad de cómputo a su disposición de la seguridad de la red. Este esquema permite una competición casi perfecta entre proveedores para ofrecer la mayor capacidad al menor precio.
- *Descentralización de la red*: el principal determinante en este punto es que la red no dependa de un número pequeño de actores que puedan llegar a controlarla y, por lo tanto, asociarse para poder modificarla.

En este sentido, en los diez años de funcionamiento de Bitcoin no ha habido fallos de seguridad atribuibles al sistema, sino, en la mayoría de los casos, a los intermediarios que han hecho uso de él (por ejemplo, monederos electrónicos). Aun cuando existe un grado de concentración en el minado de la moneda y los costes operativos (energéticos) varían sustancialmente, Bitcoin cuenta con importantes incentivos económicos para sus validadores que actualmente suponen 20 millones de dólares diarios.

*Escasez absoluta*: una de las principales ventajas del criptodinero es la capacidad de poder definir su «política monetaria» que queda fijada sin modificaciones, salvo que toda la comunidad decida hacerlo median-

te consenso. Dado que cuanto mayor es la red, mayor es la diversificación, es complicado alcanzar este amplio consenso y, cuando se opta por crear una nueva versión del protocolo, lo que suele hacerse es asignarle un nombre nuevo, lo que se conoce como un *fork* o bifurcación de la red. Esto permite crear un activo que tiene una escasez absoluta, puede agotarse o tener recursos limitados a la emisión.

*Coste de transacción cercano a cero*: entre las principales ventajas del criptodinero es que su coste de transacción es casi cero si se considera como tal el coste de la información que se transmite por Internet. El coste asociado a cada transacción que actualmente se imputa es solo por mantener la red segura y se realiza por transacción. Con grandes cantidades de transacciones, ese coste se aproxima a cero. Cuestión distinta son los costes operativos asociados al minado, entre otros el energético que, como se ha señalado anteriormente, son variables y pueden ser importantes.

*Activo inembargable*: el criptodinero no puede ser embargable al no existir ninguna empresa a la que se pueda realizar un requerimiento de este tipo.

*Dinero programable*: esta tecnología permite añadir al dinero capacidades de programación, lo que supone poder implementar dentro del propio activo cualquier tipo de reglas que rijan su uso, sin necesidad de que diferentes entidades lo implementen. Se podría, por ejemplo, definir un dinero para que cualquier transacción pueda cobrar una comisión de forma automática, como ahora se está realizando con algunas criptomonedas


para, con esos ingresos, seguir invirtiendo en la seguridad de la red. Esta capacidad de programación es probablemente una de las posibilidades que puede ser mejor aprovechada por las entidades bancarias para aumentar la eficiencia si adoptan protocolos de este tipo en algunas de sus transacciones habituales.

## 5. ARQUITECTURA Y VENTAJA DE LAS FINANZAS DESCENTRALIZADAS

El criptodineró es la primera implementación del concepto que conocemos como finanzas descentralizadas (*DeFi*). En su versión más purista, *DeFi* implica una descentralización de todos y cada uno de los procesos (gobernanza incluida). En su versión más restringida o de *open finance*, se trata de arquitecturas abiertas que solo cumplen algunas de estas características de descentralización. En su conjunto, son el nuevo paradigma tecnoeconómico que ofrece una arquitectura mucho más eficiente para el ecosistema de *fintech*. La idea es la capacidad de transformar los productos tradicionales financieros en servicios que se construyen sobre protocolos confiables y transparentes que operan sin necesidad de intermediarios.

Sin embargo, muchas empresas y servicios *fintech* siguen protocolos algo más limitados, apoyados fundamentalmente en desarrollos de *software* privados con algún grado de concentración, mientras que los productos de finanzas descentralizadas se expresan en protocolos de código abierto. La comparación entre ambas arquitecturas se describe en el gráfico 3 (De Angelis,

GRÁFICO 3  
COMPARACIÓN ENTRE  
PROTOCOLOS *FINTECH* Y *DeFi*



Fuente: De Angelis (2018).

2018). Las principales diferencias se generan entre un sistema de confianza con amplios controles burocráticos –*trust-based software*– y más centralización (*fintech* estándar) y un sistema completamente descentralizado donde la confianza adicional reside, precisamente, en un *software* superior –*trust minimized software*– de descentralización con burocracia mínima (*DeFi*). Sobre *DeFi* existen en la actualidad muchos proyectos que replican todos los servicios financieros, incorporando nueva innovación que hasta la fecha no existía en el entorno tradicional. Todos ellos comparten el apoyo en protocolos descentralizados. Entre las ventajas que proporcionan para las actividades financieras, destacan:


- *Acceso universal a servicios financieros*: permiten el acceso a una serie de servicios básicos financieros a cualquier persona o dispositivo conectado a Internet. Esto supone una disrupción porque ofrece un acceso mundial no limitado geográficamente, en muchos casos sin necesidad de identificarse. De forma efectiva, esto introduce una disyuntiva entre la necesidad de identi-

ficación de clientes por políticas que intentan controlar actividades delictivas en el mundo, y la posibilidad de banquizar a gran parte de la población que ahora no lo está. Esta arquitectura globaliza de forma efectiva el concepto de servicios financieros básicos, si bien, los requerimientos de identificación de la normativa financiera están propiciando que algunos de esos protocolos comiencen a desarrollar funcionalidades de privacidad.

- *Niveles de seguridad*: como se ha señalado anteriormente, se trata de redes (como Bitcoin o Ethereum) que han demostrado un nivel de seguridad elevado. Esto las posiciona como sistemas ideales para delegar el registro de activos y de información tan importante hoy en día en el sector bancario, con un coste muy inferior al que asumen las entidades financieras por realizar esta actividad. Al tener arquitecturas distribuidas donde la custodia de estos activos se delega en el propio cliente, también se minimiza el coste. Si bien, algunas empresas que se están especializando en servicios de custodia digital para instituciones financieras ofrecen distintos niveles de descentralización.
- *Arquitecturas de desarrollo abiertas*: una de las principales ventajas es el carácter abierto del *software* de la plataforma, lo que permite recibir sugerencias y aportaciones para la mejora continua de la eficiencia, así como ir añadiendo servicios adicionales a los protocolos. Esto permite que haya arquitecturas de va-



GRÁFICO 4  
SISTEMA DE CAPAS (LAYERS) DE ETHEREUM



Fuente: Hoffman (2019).

rios niveles que utilizan diferentes protocolos en diversas capas. Ello es particularmente intenso en el caso de la arquitectura financiera en capas de Ethereum.

Hoffman (2019) proporciona una aproximación visual muy ilustrativa de la seguridad y el sistema de capas del caso de Ethereum (gráfico 4). En este sistema, cada capa (*layer*) tiene un cometido añadido. La *layer* 0 es la propia criptomoneda en sí, ethereum, que sirve de soporte financiero para todas las transacciones. La primera y segunda *layer* corresponden a aplicaciones de software destinadas a facilitar actividades de ahorro que incorporan ya su comisión y tipo de interés automáticamente. La tercera *layer* es la que utiliza las capas anteriores para generar un ecosistema abierto de aplicaciones que emplee las facilidades de crédito y depósito de

Ethereum. El cuarto nivel son todas las aplicaciones desarrolladas por usuarios para dar liquidez y facilitar cualquier tipo de transferencia (por ejemplo, monederos electrónicos).

El nivel de innovación en estas arquitecturas proporciona un acelerado desarrollo de soluciones y viene a imitar a las arquitecturas de otras *bigtech* como Apple Store o Google Play, pero con carácter abierto para que se multiplique el número de aplicaciones que usan el ecosistema.

– *Gobernanza y participación de la comunidad*: una de las más importantes funcionalidades de estos protocolos es su gobernanza descentralizada, lo que permite una mayor implicación de la comunidad de programadores y desarrolladores, así como la definición de incentivos para los mismos. En todo caso, el

debate sobre la propiedad y protección de los datos ha puesto en cuestión lo que había sido considerado como una de las principales ventajas competitivas de las grandes plataformas: la posibilidad de captar grandes cantidades de información para poder extraer valor y redistribuirlo.

## VI. CONCLUSIONES

El nuevo paradigma que suponen las finanzas descentralizadas constituye un ingrediente esencial de la nueva infraestructura global de los servicios financieros. La arquitectura define importantes ventajas competitivas que están permitiendo una considerable expansión de estos protocolos, cuyo mayor exponente ha sido Bitcoin, una criptomoneda que almacena valor de 150.000 millones de dólares. De forma similar, Ethereum se ha consolidado como la plataforma para implementar servicios financieros descentralizados y esto ha permitido, entre otras cosas, que se hayan emitido más de 31.000 millones de dólares en ofertas iniciales de criptoactivos (*ICO*, *initial coin offering*) desde 2017. Aunque estas criptomonedas y los servicios que ofrecen sus aplicaciones puedan estar sometidos a cierta volatilidad, la tecnología subyacente de descentralización de protocolos de información y registro constituye una alternativa esencial para las entidades financieras.

En la actualidad, los servicios financieros de finanzas descentralizadas (*DeFi*) han conseguido gestionar más de 600 millones de dólares, siendo uno de los crecimientos más importantes de las aplicaciones financieras de las últimas décadas.



En todo caso, la aplicación de *DeFi* a las finanzas encara importantes desafíos. En particular, su encaje en la regulación financiera, en la medida en que los registros descentralizados ofrecen, por naturaleza, mayores retos para su seguimiento y control.

Es posible que en un futuro estas arquitecturas supongan una alternativa para el acceso a servicios financieros universales básicos y que vayan teniendo un mayor volumen. Es esta perspectiva, asimismo, la que genera una inquietud adicional reguladora y supervisora, en la medida en que con una penetración elevada, las *DeFi* supongan un riesgo para la estabilidad global financiera.

En este artículo se destacan, en cualquier caso, las ventajas competitivas que ofrecen estas arquitecturas descentralizadas para el sector financiero tradicional, sobre todo el bancario. El corolario de las diferentes propuestas es que *DeFi* puede incorporar ventajas para ofrecer servicios financieros universales y globales, en arquitecturas muy sólidas y con modelos de gobernanza más inclusivos.

#### NOTA

(\*) Otra afiliación: CryptoPlaza.

#### BIBLIOGRAFÍA

DE ANGELIS, T. (2018). *DeFi vs Fintec*. Token Economy blog.

(7 de noviembre). <https://tokeneconomy.co/defi-vs-fintech-d152bae2585c>

HOFFMAN, D. (2019). *Ethereum, the digital financial stack* (25 de julio). Medium/Coinmonks blog: <https://medium.com/coinmonks/ethereum-the-digital-finance-stack-4ba988c6c14b>

MONEGRO, J. (2016). *Fat Protocols*. Union Square Venture (USV) Blog. (8 de agosto). <https://www.usv.com/writing/2016/08/fat-protocols/>

NAKAMOTO, S. (2008). *Bitcoin: A Peer-to-Peer Electronic Cash System*. <https://bitcoin.org/bitcoin.pdf>

PÉREZ, C. (2010). Technological revolutions and techno-economic paradigms. *Cambridge Journal of Economics*, 34(1), pp. 185-202.

## Resumen

El aumento de las soluciones tecnológicas disponibles y de sus capacidades, sumado a la cristalización del fenómeno *big data* y los recientes avances de la inteligencia artificial, están concediendo a la industria financiera un mundo de nuevas posibilidades de gestión. De forma continua, las personas, los negocios y las propias máquinas están generando multitud de datos e información susceptible de generar movimientos de gran magnitud en los mercados financieros. Esto exige a los grandes gestores desarrollar sistemas que estén conectados a todas las fuentes de información, interpretando y analizando datos de forma continua, y tomando de forma autónoma decisiones inmediatas de inversión a partir de ellos. Y en todo ello, la inteligencia artificial y en particular el *machine learning*, juegan un papel fundamental. Esto está provocando que aproximadamente dos tercios de las operaciones que reciben los mercados financieros sean generadas por *bots* de forma automática. Esta importante transformación que está sufriendo el sector permite intuir que la supervivencia de las empresas del sector en los próximos años, sin duda, estará determinada por la incorporación de estas tecnologías.

*Palabras clave:* inteligencia artificial, industria financiera, *machine learning*.

## Abstract

The increase in available technological solutions and their capabilities, coupled with the crystallization of the big data phenomenon and the recent advances in artificial intelligence, are giving the financial industry a world of new management possibilities. On a continuous basis, people, businesses and the machines themselves are generating a multitude of data and information that can generate large-scale movements in financial markets. This requires large managers to develop systems that are connected to all sources of information, interpreting and analyzing data continuously, and making autonomous immediate investment decisions from them. And in all this, artificial intelligence and in particular machine learning, play a fundamental role. As a result of this, approximately two thirds of the operations currently traded in financial markets are automatically generated by *bots*, underlying the fact that embracing new technologies will play a major role on companies future development and success.

*Keywords:* artificial intelligence, financial industry, machine learning.

*JEL classification:* G10.

# APLICACIONES DE LA INTELIGENCIA ARTIFICIAL A LOS MERCADOS FINANCIEROS

Igor ALONSO

*Accurate Quant Agencia de Valores, S.A.*

Adrián CARRIO

*Centro de Automática y Robótica, Universidad Politécnica de Madrid/CSIC*

## I. INTRODUCCIÓN

*Un tuit hunde los mercados*

VIERNES 23 de agosto de 2019, en plena guerra comercial entre EE.UU. y China, el gigante asiático anuncia a través de un comunicado oficial del Ministerio de Finanzas la imposición de aranceles a las importaciones estadounidenses a partir del 1 de septiembre. Esto provoca una rápida caída del 0,85 por 100 en la cotización de los futuros del índice bursátil S&P 500 en un intervalo de apenas cinco minutos.

Tres horas más tarde, el presidente de EE.UU., Donald Trump, a través de su cuenta de Twitter, anuncia una respuesta inminente en forma de nuevos aranceles, e incluso solicita a las empresas americanas que dejen de producir en China. En cuestión de once minutos, tras la publicación del tuit, el mismo índice se desploma con una caída superior al 1,82 por 100 (1).


Dos formas de comunicación, dos noticias negativas, una misma consecuencia.

Vivimos actualmente en los mercados financieros una época convulsa, con valoraciones muy volátiles debido a las diversas incertidumbres que hay encima de la mesa: además de la guerra

comercial que hemos comentado, vivimos una desaceleración económica a nivel global y con la posibilidad real de un *brexít* sin acuerdo. Con ello, un simple tuit puede derivar en rápidas y fuertes correcciones del mercado.

De sobra es conocido que la información es crucial en la toma de decisiones y que el hecho de disponer de ella antes que el resto es una ventaja clara frente al mercado, luego en este sentido, si tuviésemos a nuestro alcance la posibilidad de obtener de forma instantánea el comunicado de China y el tuit de Trump, la capacidad de tener un algoritmo que pudiese interpretar de forma inmediata el contenido del mismo, en sentido positivo o negativo para el mercado, y un sistema de decisión que ejecutase operaciones de compra o venta directamente contra el mercado en función de aquella, ¿no podríamos sacar rendimiento de ello? Fijémonos en que las correcciones posteriores a las noticias, aunque se producen en cuestión de minutos, son una eternidad para un ordenador.

Estas estrategias son un ejemplo de las que, desde hace muchos años, un grupo muy selecto de grandes gestoras internacionales han implementado en sus carteras de inversión con grandes resultados, y en estas, la inteligencia artificial, como



veremos más adelante, ha sido pieza clave.

En el presente artículo veremos cómo hoy en día, gracias a las nuevas posibilidades tecnológicas, la generalización de la creación, almacenamiento y distribución de información, y a las nuevas metodologías en inteligencia artificial, las estrategias cuantitativas de gestión están ganando terreno en los mercados financieros.

## II. TRANSFORMACIÓN DE LOS MERCADOS FINANCIEROS

Desde hace años estamos siendo testigos de profundos cambios en los mercados financieros y en cómo los diferentes agentes de la industria intervienen en él. Si bien en las últimas décadas presenciamos una transformación profunda en su funcionamiento, en esta década, se está produciendo un cambio notable en el *buy side* (2).

Con respecto al funcionamiento de los mercados financieros, hoy en día, prácticamente la totalidad de los activos financieros se negocian por vía electrónica. Este hecho ha supuesto mejorar radicalmente las funciones

que todo mercado debe ofrecer para su correcto funcionamiento: mejorar el acceso a los participantes, ofrecer un mayor grado de seguridad y transparencia, otorgar mayor liquidez, y finalmente mejorar la formación de precios. Este proceso de cambio fue posible gracias a la evolución tecnológica de conectividad a nivel global, con la generalización y consolidación del uso de Internet.

Por otro lado, históricamente, en las carteras de inversión ha imperado la *beta* de mercado (3) y la discrecionalidad de los gestores en sus actuaciones. Sin embargo, en los últimos años, debido a las posibilidades que ofrece la tecnología, a la cristalización del fenómeno *big data* (4) en los mercados financieros, y a las nuevas metodologías de inteligencia artificial, están ganando terreno considerablemente estrategias donde las decisiones se fundamentan únicamente en datos y probabilidades.

Los agentes financieros adoptan sus decisiones de compra y venta en función de sus necesidades y objetivos, pero fundamentalmente en base a la información de que disponen. Gran

parte de esta información, que hasta hace años era accesible de forma periódica o puntual, cada vez, además de crecer en cantidad y en calidad, se encuentra disponible en tiempo real. En este sentido, los gestores no pueden permitirse el lujo de obviar las grandes cantidades de información que la sociedad o los agentes económicos generan en cada momento, y para ello necesitan desarrollar metodologías que le posibiliten procesarla, interpretarla, analizarla y finalmente tomar decisiones en consonancia con ella. Y esto último, está viniendo de la mano de la inteligencia artificial y en particular del *machine learning*.

Esto está derivando en que, hoy en día, se considera que aproximadamente entre el 60 por 100-70 por 100 de las operaciones de los mercados financieros se realizan automáticamente por máquinas, y no por personas.

### *La tecnología como eje central de la evolución de los mercados financieros*

No es posible entender la transformación continua de los mercados financieros sin la evolución de la tecnología. Si bien hace años la tecnología posibilitó la digitalización de los mercados financieros gracias al desarrollo y generalización de la conectividad, durante los últimos años el desarrollo tecnológico se ha centrado en el crecimiento de la capacidad computacional y de almacenamiento.

En 1965, Gordon Earle Moore, cofundador de Intel, al analizar la evolución de las capacidades computacionales entre 1959 y 1965, formuló una extrapolación, conocida como ley

de Moore, donde especulaba que la cantidad de componentes (transistores, resistencias y condensadores) integrables en un único chip se duplicaría cada doce meses (5).

Independientemente del período en el que la tecnología permite duplicar sus capacidades, la ley de Moore es una de las predicciones tecnológicas más duraderas que se han formulado, y nos da una idea de la evolución de las capacidades tecnológicas en las que nos vemos inmersos. Se considera el emblema de la era de la información, la marcha implacable del chip de ordenador que permite una revolución técnica, económica y social nunca antes experimentada por la humanidad.

Con respecto al crecimiento de la capacidad de almacenamiento de información, por ponerla en perspectiva con un ejemplo, la primera unidad de disco duro fue creada por IBM en 1956, tenía una capacidad de 5 *megabytes* (MB) y era del tamaño de una habitación. En 1980 se lanzó la primera unidad de disco duro «pequeña», con la misma capacidad de almacenamiento, pero que entraba en un ordenador personal. Diez años después, en 1990, un disco duro normal podía almacenar desde 40 a 100 MB, en función del modelo. Hoy en día, un disco duro de 10 cm, tiene una capacidad de 15 *terabytes* (TB) (15 millones de MB). Si, además, nos fijamos en el coste de almacenamiento, en los últimos treinta años, el coste de almacenamiento de gigabytes (1.000 MB) ha pasado de aproximadamente 100.000 euros a apenas unos céntimos. En resumen, de una forma exponencial, se ha evolucionado a más capacidad

de almacenamiento, en menor espacio físico y a menor coste.

Hasta que la informática cuántica sea una realidad, lo cual probablemente se produzca en un futuro próximo, y se produzca una auténtica explosión de la capacidad y velocidad computacional, lo cierto es que la actual tecnología sigue posibilitando procesar, analizar y almacenar cada vez más y más información de forma más rápida y económica.

Adicionalmente a las mayores capacidades de los ordenadores, la generalización de la informática paralela o distribuida ha supuesto del mismo modo un revulsivo considerable. La posibilidad de compartir recursos de forma remota actualmente permite incrementar las capacidades tecnológicas y de almacenamiento, lo cual también se conoce como *cloud computing*. Para el año 2020 se estima que la tercera parte de todos los datos se procesarán a través de la nube (6). Hoy en día, a través de soluciones tecnológicas *software as a service* (SaaS), *platform as a service* (PaaS) o *infrastructure as a service* (IaaS), cualquier entidad puede acceder fácilmente a estas nuevas posibilidades a un coste mucho más accesible.

### III. BIG DATA EN LOS MERCADOS FINANCIEROS

La verdadera disrupción que en el mundo de la gestión se ha producido en los últimos años ha venido de la mano de la información. La toma de decisiones siempre viene condicionada por los datos que tenemos a nuestro alcance y desde hace unos años se han producido dos circunstan-

cias claves: la generación de datos ha crecido de forma exponencial y el acceso a estos se ha vuelto prácticamente instantáneo.

Aunque su capacidad de incidir en los mercados aún está vigente, la transcendencia de indicadores macroeconómicos tradicionales, tales como el cambio en nóminas no agrícolas (*non-farm payrolls*), el índice ISM (elaborado en EE.UU. por el Institute for Supply Management) manufacturero y no manufacturero, o incluso publicaciones de evolución de IPC, del PIB, comunicados de bancos centrales sobre política monetaria, han perdido fuerza frente a las nuevas fuentes de información, ya que aquellas se generan con una frecuencia baja, y en ningún caso de manera continua.

Hoy en día, la inmensa mayoría de la información que se recopila se hace de forma electrónica, dado que gran parte de nuestra actividad personal y profesional se hace *online*, y esto nos puede dar una idea de la magnitud de datos que en cada segundo se está generando a nivel global. Esto ha originado la creación de un gran negocio en torno a la generación, tratamiento y suministro del dato (7), con la aparición de multitud de entidades especializadas en múltiples campos de la información, facilitando a la industria financiera con ello el acceso a los mismos. Y esta información va desde gustos, preferencias, actividades, u opiniones de personas o colectivos, hasta información de negocios como puede ser número de visitantes a centros de negocios, transacciones de compra venta de artículos, predicciones meteorológicas sobre zonas agrícolas, situación de petroleros en diferentes partes del mundo, etcétera.



### *Tres características del big data: volumen, velocidad y variedad*

Durante la última década, la recopilación sistemática de información, interpretación, organización y difusión han ido configurando el concepto de *big data*. Tres son las características básicas que concentra el término: volumen, velocidad y variedad.

El tamaño de los datos recopilados y registrados a través de diferentes medios es impresionante, y creciente en el tiempo, siendo el límite mínimo de referencia para ser considerado «*big*» superior cada vez. Se considera que aproximadamente el 90 por 100 de los datos almacenados actualmente han sido recopilados en los dos últimos años, y, según estimaciones, se considera que entre 2015 y 2020 se multiplicará por diez su volumen.

La segunda característica es la velocidad. Disponemos de datos prácticamente en tiempo real, bien recibiendo en *streaming* (de forma continua) o en *batch mode* (por lotes). Una gran cantidad de estos datos son recopilados y distribuidos al mismo tiempo, sin apenas haber sido tratados.

La tercera característica es la variedad del formato de la información que se recibe. En función de la fuente, el formato puede ser tanto estructurado (como suele producirse en formatos de texto, CSV, SQL), en formato semiestructurado (habitual en formato HTML, JSON), o completamente desestructurado como pueden ser los procedentes de vídeos, imágenes, blogs, etc. La estructura en la recepción se vuelve clave en el tratamiento de la información, ya que añade o elimina complejidad al mismo.

La veracidad está considerada hoy en día como una característica adicional del *big data*, la cual cobra especial relevancia en los mercados financieros. Esta hace referencia a la calidad o exactitud del dato y a su valor como tal. De la calidad del dato dependerá la validez de cualquier estudio o estrategia de actuación establecida. Existen muchas bases de datos que necesitan depuraciones por poder presentar vacíos de información, duplicidades o simplemente incoherencias. Esta es una labor crítica y una de las que más recursos consume por parte de los *quants* (8).

Por otro lado, podemos clasificar la nueva generación de datos en tres apartados: datos generados por individuos, datos generados por los negocios, y finalmente los datos generados por las propias máquinas.

### *Big data generado por individuos*

Con datos generados por individuos nos referimos a toda clase de información que personas físicas, en su día a día, en su vida privada, pueden generar. Tengamos en cuenta que una gran parte de nuestras actividades cotidianas las hacemos a través de dispositivos fijos y móviles conectados a la red, y mediante aplicaciones o *softwares* de terceros donde quedan registradas. Esta tendencia ha sido creciente en los últimos años y previsiblemente continúe con esa evolución, pese a la cada vez más restrictiva normativa de protección de datos.

Su procedencia puede ser de redes sociales, como son Twitter, LinkedIn, etc, de blogs generados por particulares, o bien por noticias o publicaciones ge-

nerales. Por otro lado, puede proceder también de entidades especializadas en recopilar información de *apps* o webs especializadas, registrando búsquedas, altas y bajas, descargas, facturación, etc. Y, por último, también puede proceder de búsquedas web y datos personales aportados voluntariamente por los usuarios, obtenidos, por ejemplo, de proveedores de gestores de correo electrónico.

Esta clase de datos suelen ser recibidos como texto, y frecuentemente de forma desestructurada, procedentes de múltiples fuentes. Este tipo de información suelen ser muy apreciada para indicar tendencias o *sentimientos de mercado* (9).

Entre los ejemplos prácticos de proveedores de esta clase de información contamos con iSENTIUM, proveedor que proporciona datos de sentimiento de mercado en tiempo real basado en mensajes de Twitter. Su información puede proporcionar a sus usuarios una herramienta de predicción de movimientos de mercado a corto plazo. Al comienzo del artículo, hablábamos de la incidencia en los mercados de un solo tuit, con mucha relevancia por proceder del presidente de EE.UU., en este caso se recogería la opinión de millones de personas que, aunque con menor incidencia de forma individual, como colectivo puede resultar un indicador adelantado extraordinario.

Otro ejemplo lo tenemos con RavenPack, proveedor que proporciona indicadores basados en noticias especializadas, novedades regulatorias, comunicados de prensa, etc. Este tipo de proveedores proporciona información que incluiría el comunicado



oficial que emitió China y al que hacíamos referencia al inicio.

Por último, también tenemos proveedores más conocidos como son Alexa o Google, los cuales nos pueden proporcionar información muy valiosa en torno a búsquedas y seguimiento web.

### Big data generado por operaciones comerciales

Se trata de datos producidos o recopilados por todo tipo de entidades, públicas y privadas. Nos referimos a la información que las entidades pueden ofrecer sobre transacciones comerciales, empleo de tarjetas de crédito, afluencia a centros comerciales, variaciones de inventarios, cadenas de suministro de mercancías, etc. O al conjunto de grandes agrupaciones de datos generados por entidades públicas. Este tipo de información se presenta de una forma más estructurada que la proporcionada por los individuos y sus datos son considerados como buenos indicadores adelantados de métricas corporativas.

En este caso, tenemos como ejemplo de datos de organismos públicos como WTO (World Trade Organization) o IMF (International Monetary Fund), que suministran datos utilizados para estrategias cuantitativas a más largo plazo y de baja frecuencia. Otro ejemplo de información de operaciones comerciales la tenemos con EagleAlpha, que suministra gran variedad de información, como por ejemplo información sobre transacciones *online* de empresas integrantes del índice bursátil S&P 500.

### Big data generado por sensores

Por último, tenemos los datos generados por sensores: da-

tos recopilados de forma automática a través de sensores integrados en diversos dispositivos. Estos datos son generados fundamentalmente de forma no estructurada y su tamaño es con frecuencia sustancialmente más grande que los flujos de datos generados por humanos o procesos. El ejemplo más conocido es la imagen vía satélite que puede usarse para monitorear actividades económicas, como la evolución de reservas de materias primas, de construcciones, envíos de estas o de materiales, producción de artículos, etc.). Otro ejemplo son los datos procedentes de la geolocalización que pueden ser empleados por ejemplo para rastrear el tráfico peatonal en tiendas minoristas, en aparcamientos, o de barcos de mercancías en puertos, etc. Más ejemplos tenemos con la información procedente de cámaras fijas en lugares de interés, sensores climáticos y de contaminación, etc. Con total probabilidad, es el futuro concepto de Internet de las cosas (IoT), que consiste en la práctica de incorporar microprocesadores y tecnología de red en todos los dispositivos electrónicos personales y comerciales.

Entidades como Orbital Insights, Descartes Labs, o Rezatec son entidades que pueden ofrecer información muy valiosa para establecer estrategias sobre materias primas como petróleo o bienes agrícolas.

### Aspectos claves del big data para los mercados financieros

Uno de los aspectos más relevantes a tener en cuenta es la relación que puede establecerse entre la información y los mercados financieros a los que

hace referencia. La mayoría de la información que hoy en día se encuentra accesible al gestor está directa o indirectamente relacionada con acciones o sectores empresariales o con materias primas, siendo menor, por ejemplo, la información generada en torno a tipos de interés y divisas, la cual se deriva más de información macroeconómica.

Otro aspecto importante es la consideración del potencial de la información, traducido en el potencial *alfa* (10) que puede aportarnos y su coste. En primer lugar, debemos considerar el coste de disponer de datos: no es igual de costoso adquirir bases de datos que nos puedan aportar sentimiento de mercado (información más pública) que otra que nos aporte información sobre transacciones con tarjeta de crédito (con un carácter mucho más privado). A esto hay que añadir, que el coste únicamente se justifica si la rentabilidad que vamos a obtener de ella es suficiente, y eso es difícil de conocer *a priori* (11). Lo cierto es que, aunque la intuición puede indicarnos que cierta información puede ser muy útil para identificar grandes oportunidades de inversión, es realmente complicado encontrar bases de datos que nos permitan por sí solas diseñar estrategias de inversión que aporten una ratio de Sharpe (12) muy elevado a nuestras carteras.

Otro factor a tener en cuenta es lo conocida o accesible que resulta la base de datos; en este sentido, existen ciertas bases de datos que hacen referencia a magnitudes fundamentales de empresas como son beneficios o ventas, donde el potencial es mucho menor, ya que esa información es más conocida y puede

estar disponible por otras fuentes. En cambio, otras bases de datos otorgan una información mucho más exclusiva, por lo que su potencial es, *a priori*, mucho más atractivo.

Otro elemento a considerar es el estado de procesamiento en el que se encuentra la información. Podemos disponer de bases de datos con información presentadas en formato informe o resumen, o bases de datos con información totalmente desestructurada. En este último caso, el tratamiento de esta información es sustancialmente más costoso que en el primero, y eso resulta un factor determinante en la rentabilidad de la adquisición.

Probablemente, el factor más importante es la calidad de los datos. En primer lugar, debemos considerar que el tamaño de la información es trascendental; cuanto más histórico dispongamos, más robustas serán las conclusiones que podamos obtener, y esto es algo de lo que no se dispone en todas las bases de datos (13). En segundo lugar, debemos tener en cuenta la forma en la que se ha obtenido (metodología) y si existen gaps de información en el historial (en este caso es trascendental conocer el porqué, si han sido aleatorios o existe algún patrón, y cómo se han solucionado).

Por último, deberíamos considerar también la disponibilidad de ella, no es lo mismo disponer de la información en tiempo real, de forma diaria, semanal, mensual, etc. Del mismo modo, no es lo mismo si existe latencia o si se producen interrupciones, ni la forma de conexión al proveedor, ya que pueden existir grandes diferencias de robustez y seguridad entre conexiones.

Recordemos la importancia que en nuestro ejemplo inicial tendría disponer de la información con unos minutos de retraso.

En definitiva, cada gestor dará más importancia a unos aspectos que a otros en función de su estilo de gestión; en unos casos, la inmediatez será clave, por ejemplo, para los gestores de alta frecuencia, pero en cambio gestores con un enfoque más tendencial ponderarán más la singularidad y exclusividad del dato.

#### IV. MACHINE LEARNING – INTELIGENCIA ARTIFICIAL

##### *Una mirada histórica*

En los últimos años ha habido una evolución significativa en el campo del aprendizaje automático o *machine learning*, un conjunto de técnicas que, combinando algoritmos matemáticos con modelos estadísticos, permiten a un sistema informático resolver tareas sin instrucciones explícitas, empleando fundamentalmente datos. El *machine learning* combina, por tanto, las disciplinas estadística e informática y se engloba dentro de un conjunto más amplio de técnicas, en lo que actualmente se conoce como inteligencia artificial.

La inteligencia artificial no es un área de conocimiento tan joven como pueda parecernos. Nació como disciplina académica en el año 1956 durante una célebre conferencia en Dartmouth, Estados Unidos, a la que asistieron los principales expertos de aquel momento, en la que se definieron sus objetivos y donde se hicieron públicos sus primeros éxitos.

Durante los primeros años de la inteligencia artificial se resol-

vieron problemas algebraicos, se demostraron teoremas geométricos y se implementaron los primeros sistemas que podían hablar en inglés. Estos avances generaron un gran optimismo (se creía en la posibilidad de replicar el cerebro humano en pocos años) y todo ello propició la inyección de grandes inversiones para acelerar su desarrollo. Sin embargo, a partir del año 74 y hasta el año 80, las grandes expectativas creadas se vieron superadas por la realidad, y la lentitud con la que avanzaban los desarrollos generó gran decepción y recortes en las inversiones.

Posteriormente, entre los años 1980 y 1987 tuvo lugar un segundo *boom* con la aparición de los llamados «sistemas expertos» o sistemas basados en reglas que permitieron resolver multitud de problemas empleando reglas lógicas y el conocimiento de personas expertas. La implantación de estos sistemas generó grandes ahorros en las empresas que los adoptaron y también provocó una gran aceleración en las empresas de desarrollo de *software* y de fabricación de *hardware* informático. Además, los avances en el desarrollo de las redes neuronales artificiales, cuya utilidad había sido discutida hasta ese momento, impulsaron su uso de manera definitiva. Todo esto generó de nuevo gran optimismo y movilizó grandes inversiones que apostaban por los avances de la inteligencia artificial.

A finales de los años ochenta y a principios de los noventa, la aparición del ordenador personal provocó el hundimiento de las empresas de *hardware* especializado, un sector de enorme peso económico. Esto, sumado a los problemas para mantener los sis-

temas expertos y a las enormes expectativas que se habían generado una vez más, provocó de nuevo decepción entre los inversores y grandes recortes. Sin embargo, debido a los avances obtenidos desde mediados de los años noventa en multitud de áreas, minería de datos, robótica, reconocimiento del habla, diagnóstico de enfermedades, etc., vivimos ya una tercera revolución de la inteligencia artificial y el optimismo ha surgido de nuevo con la resolución de algunos de los retos que se habían planteado en su nacimiento, como vencer al campeón del mundo de ajedrez o manejar de forma segura un coche sin conductor.

Desde el año 2011 con la disponibilidad de grandes volúmenes de datos, de ordenadores más potentes y de técnicas de *machine learning* más avanzadas, la inteligencia artificial se viene aplicando en un número cada vez mayor de problemas. En concreto, durante este último período se ha producido el nacimiento del *deep learning*, que se refiere al aprendizaje automático con estructura jerárquica, como el que se produce cuando se aprende a reconocer un objeto en una imagen empleando varios niveles de abstracción: reconociendo partes de dicho objeto, su estructura y/o su entorno. El avance del *deep learning* estos últimos años ha permitido grandes avances no solo en el ámbito financiero, sino también en el procesamiento de imagen, vídeo, el análisis de texto y el reconocimiento del habla.

### Machine learning

Centrándonos en los algoritmos de aprendizaje automático o *machine learning*, se dice que un algoritmo «aprende» a resolver

una tarea (por ejemplo operar un determinado activo financiero) cuando existe una forma de medir el desempeño de dicha tarea (por ejemplo, midiendo la rentabilidad diaria obtenida) y dicho algoritmo mejora su desempeño conforme adquiere experiencia (por ejemplo, operando el activo financiero durante un período de tiempo, es posible inferir automáticamente una estrategia que ofrezca resultados favorables).

Un mismo problema (operar un activo financiero) se puede plantear mediante diferentes tareas (prediciendo precios, detectando patrones, etc.) y es posible utilizar diferentes métricas para medir su desempeño (rentabilidad, pérdida máxima acumulada, ratio de Sharpe, etc.). Además, la experiencia puede ser adquirida de diferentes formas, las cuales se clasifican en tres grupos principales que dan nombre a los tres tipos de aprendizaje automático más comunes: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje por refuerzo.

### Aprendizaje supervisado

El aprendizaje supervisado o *supervised learning* se basa en tratar de imitar la inferencia que hace una persona experta para resolver una determinada tarea. Por ejemplo, si la tarea a resolver consiste en clasificar una serie temporal como tendencial o en rango, el algoritmo debe procesar un conjunto de series junto con la información sobre cuáles son tendencias y cuáles en rango. Esto último recibe el nombre de etiqueta o *label* y es el conocimiento que aporta el experto. Una vez entrenado con estos datos, el algoritmo será capaz de clasificar una nueva serie que no ha visto antes. Otra de las ta-

reas más habituales que resuelven este tipo de algoritmos junto con la clasificación es la regresión, en la cual el algoritmo no busca predecir una clase (por ejemplo, tendencial o en rango), sino el valor numérico de una o varias variables. Por ejemplo, si la tarea es predecir el precio de cierre de hoy a partir de los precios de cierre de los últimos días, el algoritmo debería entrenarse usando varios bloques de mil precios de cierre junto con el precio de cierre del día posterior a cada bloque. Este último precio de cierre sería la etiqueta de cada uno de los bloques. Como ya se mencionó anteriormente, en la actualidad se utilizan grandes volúmenes de datos, incluyendo no solo precios o indicadores técnicos, sino también información como los sentimientos de mercado, que pueden extraerse automáticamente de las noticias empleando técnicas de procesamiento del lenguaje natural y lo que se conoce como análisis del sentimiento o minería de opinión.

Para aplicar con éxito todas estas técnicas no solo habrá que elegir correctamente el mejor algoritmo (redes neuronales artificiales, árboles de decisión, SVMs –máquinas de soporte vectorial, *support vector machines*–, etc.) junto con sus parámetros, sino también realizar un estudio que garantice que no existe sesgo en el aprendizaje y que el algoritmo es capaz de generalizar correctamente cuando se le presentan datos que no ha visto anteriormente.

### Aprendizaje no supervisado

El aprendizaje no supervisado o *unsupervised learning* recibe este nombre ya que no requiere la supervisión de un experto que proporcione etiquetas, puesto que sus algoritmos son capaces

de encontrar automáticamente patrones en los datos. Algunas de las tareas más habituales que resuelven este tipo de algoritmos son la detección de anomalías y el *clustering*, en el cual se busca agrupar los datos en clústeres o grupos, de manera que los datos clasificados en un mismo clúster compartirán determinadas características y se diferenciarán de alguna manera de los datos presentes en el resto de clústeres.

Un ejemplo de la aplicación del aprendizaje no supervisado en los mercados financieros podría ser la búsqueda de patrones dentro de una serie de datos. Si tomamos la serie y la dividimos en bloques de longitud fija, podríamos utilizar un algoritmo de *clustering* para agrupar los bloques en varios grupos, de manera que una vez completado el aprendizaje cada clúster podría entenderse como un patrón y los clústeres con mayor número de bloques contendrían los patrones más frecuentes.

La clave en este tipo de algoritmos es determinar cómo se mide la distancia entre dos muestras cualesquiera, de manera que se codifique correctamente la similitud entre ellas. Como referencia, algunos de los algoritmos más comunes en el aprendizaje no supervisado son el algoritmo de *k-means*, los *autoencoders*, los mapas autoorganizados (*SOM*, *self organizing maps*) o el análisis de componentes principales (*PCA*, *principal component analysis*).

### Aprendizaje por refuerzo

Por último, el aprendizaje por refuerzo o *reinforcement learning* permite aprender a resolver una tarea mediante un sistema de castigos y recompensas. Durante

el aprendizaje, un agente interactúa con un entorno (real o simulado) observando una serie de variables conocidas como «estado» y ejerciendo acciones sobre dicho entorno. Esas acciones provocan una serie de castigos y recompensas prefijados por el usuario en lo que se conoce como función de recompensa o *reward function*. Inicialmente, el agente toma decisiones de manera prácticamente aleatoria, pero conforme recibe la realimentación de sus acciones, es capaz de discernir cuáles pueden llevarle a maximizar su recompensa y en qué momento es mejor aplicarlas. El algoritmo debe ponderar la exploración de nuevas estrategias, que le permitirán mejorar su desempeño, con la explotación de aquellas que ya ha descubierto. El objetivo final es que el agente genere por sí mismo un sistema de reglas según el cual sepa en cada momento, dado un estado, tomar la acción que le permita obtener las máximas recompensas posibles.

Un ejemplo de la aplicación de este tipo de algoritmos a los mercados financieros podría ser la gestión de una cartera, en la cual un gestor o *trader* debe decidir si compra o vende un determinado activo financiero en función de los recursos disponibles para invertir y del estado del mercado. El agente (que en este caso equivaldría al *trader*) podría entrenarse en un entorno de simulación antes de operar en el mercado real. En dicho entorno de simulación se simularía la fluctuación del valor de los activos (con datos reales o simulados) y de la cartera del agente, lo cual constituiría el estado (al cual se podrían añadir otras variables de interés como por ejemplo indicadores técnicos de los activos), en base al cual el agente toma sus decisiones. Las acciones serían el lanzamiento

de órdenes de compra o venta de activos, las cuales tras ejecutarse generarían beneficios y pérdidas, que se traducirían en recompensas y castigos en base a la función de recompensa fijada de antemano, que podría ir encaminada, por ejemplo, a obtener el máximo beneficio con la mínima exposición. Como se ha explicado anteriormente, el agente comenzaría operando de manera aleatoria, pero después de determinado número de operaciones, el agente sería ya capaz de tomar decisiones que tendiesen a generar recompensas más altas cada vez en base a la experiencia adquirida.

Una de las grandes fortalezas del aprendizaje por refuerzo es que permite ponderar el beneficio inmediato frente al beneficio a largo plazo. El objetivo perseguido por el agente no tiene por qué ser necesariamente obtener el máximo beneficio de manera inmediata tras una acción, sino el beneficio en el largo plazo, aunque ello conlleve un «castigo» inmediato. Ejemplos de esto serían el incurrir en costes de operación para abrir una posición que se espera cerrar con beneficios o el cerrar una posición con el objetivo de minimizar una pérdida.

Entre los algoritmos de aprendizaje por refuerzo más utilizados destacan aquellos que aprenden *off-policy*, es decir, ignorando las reglas aprendidas hasta ese momento, como por ejemplo *Q-Learning* y aquellos que sí la tienen en cuenta como *state-action-reward-state-action* (*SARSA*), *non-adjacent form* (*NAF*) y *proximal policy optimization* (*PPO*), conocidos como algoritmos *on-policy*.

Los avances recientes en el campo de la inteligencia artificial



y en particular en el *machine learning* están poniendo herramientas muy potentes a disposición de los profesionales de las finanzas. La rápida y correcta adopción de estas herramientas, sin duda, contribuirá a la toma de decisiones financieras más informadas, controlando su riesgo de manera mucho más eficaz.

### *La máquina supera al hombre*

Con la inteligencia artificial, en definitiva, lo que se pretende es replicar el proceso cognitivo humano, donde se recibe información, se procesa y analiza, se adoptan decisiones, y se sacan conclusiones en función de los resultados. En este sentido, el objetivo es claro y alcanzable, en la medida que seamos capaces de descifrar todos los condicionantes que rodean al ser humano en su toma de decisiones, tanto sean considerados racionales como emocionales. Un *bot* (14) debería ser capaz de replicar las decisiones del ser humano con mayor o menor dificultad. Incluso, si el proceso de réplica cognitiva permite discernir ciertos condicionantes que podemos considerar perjudiciales en la toma de decisiones, por ejemplo, las más puramente emocionales o sesgadas, podría mejorar al ser humano, más allá de las ventajas evidentes que una máquina puede aportar por el simple hecho de poder tratar muchísima más información en un tiempo menor, y contemplando muchísima más casuística.

Procesos de réplica humana «mejoradas» se han producido en los últimos años en diversos ámbitos, como por ejemplo el caso de la supercomputadora desarrollada por IBM Deep Blue que consiguió batir al campeón del mundo de ajedrez Garri

Kaspárov en 1997. Este ordenador, a través de algoritmos de inteligencia artificial, gracias a su gran capacidad de cómputo, era capaz de profundizar en nodos, es decir, en búsquedas de soluciones tras cada jugada. Era capaz de calcular 200 millones de posiciones por segundo, con un objetivo claro, maximizar las ganancias y minimizar las pérdidas de cada jugada (15). Debemos considerar que se trata de un juego de estrategia basado en piezas y casillas finitas, y por tanto acotables (16). Esto, ya de por sí, concede una ventaja al ordenador, en la medida de disponer de un universo finito de posibilidades parametrizables.

Otro caso reseñable de la competición del ser humano contra la máquina es el caso del juego Go, juego de estrategia de origen chino con una antigüedad de más de 2.500 años, y que en la antigüedad fue considerado como una de las cuatro artes esenciales de la antigua China. Se trata de un juego complejo de dos jugadores, donde la estrategia es clave. Sobre este juego, Google Deepmind, división especializada de Google, desarrolló un *software* denominado por AlphaGo (17) capaz de ganar al campeón del mundo de Go. A través de una metodología de inteligencia artificial basada en redes neuronales, desarrollaron un *software* basado en aprendizaje supervisado por jugadores expertos, reforzando el aprendizaje jugando contra sí misma.

Por último, y por poner un ejemplo de superación de la máquina al hombre en el campo del lenguaje y del conocimiento, tenemos el caso de Watson de IBM donde batió a los mejores concursantes de Jeopardy, un concurso de preguntas

y respuestas de la televisión de Estados Unidos de conocimiento general. En sí, el *software* desarrollado por IBM tenía acceso a prácticamente ilimitadas fuentes de información, bien a través de bases de datos, enciclopedias y acceso a Internet, pero realmente, el hecho diferencial es que fuese capaz de acceder, seleccionar y procesar la información más adecuada en cada momento, a través de interpretar preguntas en un lenguaje coloquial, es decir, siendo capaz de interpretar dobles sentidos, ironías y juegos de palabras, así como ser capaz de detectar matices del lenguaje ambiguo cuando el significado depende del contexto.

Estamos ante tres casos en los que un *software* desarrollado con inteligencia artificial es capaz de superar al hombre. Se trata de eventos donde el objetivo es replicar el proceso cognitivo del ser humano, pero mejorando los resultados, al disponer de más información de forma más rápida.

## **V. TRADING CON INTELIGENCIA ARTIFICIAL**

La aplicación de la inteligencia artificial no es algo nuevo en la industria financiera, aunque en los últimos años está adquiriendo un protagonismo especial. Como comentábamos en la introducción del presente artículo, de hecho, existen entidades que desde hace décadas vienen implementando estrategias que de alguna manera incluyen inteligencia artificial en su gestión.

### *Trading algorítmico*

Los cimientos de la inteligencia artificial en los mercados financieros vienen de la mano del *trading* (18) algorítmico.



Se trata de estrategias que, gracias a potentes ordenadores e información histórica, emplean complejos algoritmos matemáticos para tomar sistemáticamente decisiones de inversión. Estos algoritmos pueden basarse en múltiples variables técnicas de precios, bien en ratios fundamentales, ratios macroeconómicas, o cualquier otra variable cuantificable de la que se disponga y con suficiente información histórica para contrastarlo empíricamente.

La gran explosión de este tipo de estrategias de *trading* se produjo en los años ochenta, cuando las principales bolsas empezaron a posibilitar el enrutamiento automático de órdenes y las grandes instituciones de inversión empezaron a invertir en ordenadores con grandes capacidades computacionales. Aunque por aquel entonces este tipo de estrategias estaban limitadas a unas cuantas entidades, con el tiempo se han ido generalizando hasta alcanzar porcentajes muy elevados.

Hay casos especialmente exitosos de empresas que han triunfado empleando estrategias de *trading* algorítmico, como es el caso de Renaissance Technologies LLC, *hedge fund* –fondos de cobertura o fondos de inversión libre– fundado en 1982 por James Simons, un matemático galardonado y exdescifrador de códigos de la Guerra Fría. Gracias a su fondo Medallion, que se gestiona en base a modelos matemáticos estadísticos desarrollado por reconocidos físicos y matemáticos sin perfil económico, ha sido considerado como el gurú de la gestión cuantitativa y uno de los mejores *traders* de la historia.

Otros casos similares son, por ejemplo, D. E. Shaw & Co., L.P. entidad fundada en 1988 por

David E. Shaw conocida por desarrollar sofisticados modelos matemáticos y avanzados programas informáticos especializados en explotar anomalías en los precios de los mercados. O por ejemplo Two Sigma Investments, fundada en el año 2001 por John Overdeck, David Siegel y Mark Pickard.

En todos estos casos, sus estrategias están basadas en métodos cuantitativos de gestión y, según ellos mismos reconocen, en inteligencia artificial, por lo que pueden considerarse que son una evidencia de la aplicabilidad con éxito de la gestión a través de algoritmos.

Dentro de este tipo de estrategias, detengámonos en una con un enfoque más inmediato: *high frequency trading*.

### *High frequency trading*

El *high frequency trading* consiste en la negociación de activos financieros mediante la generación de miles y miles de órdenes de compra y venta enviadas al mercado en fracciones de segundos. Estas órdenes tienen una vida media muy corta, ya que buscan pequeñas oportunidades de beneficio en cada operación. Esta forma de operar no se basa en predecir el valor futuro de los activos financieros, sino aprovechar pequeñas ineficiencias del mercado u oportunidades que ofrece la formación de precios en determinados momentos. Esto requiere el empleo de *bots* o estrategias automatizadas que permitan detectar oportunidades de negocio instantáneas, mediante ordenadores con extraordinarias capacidades computacionales necesariamente ubicados muy cerca de los centros de negociación, en aras de tener una

conexión instantánea sin apenas latencia. Estas estrategias automatizadas incluyen complejos algoritmos que analizan el precio de los activos y, sobre todo, el libro de órdenes existente en cada momento.

Estas estrategias necesitan analizar mucha información en muy breve espacio de tiempo, información que, gracias a las nuevas fuentes de información, cada vez son mayores y más diversas y precisan de nuevas tecnologías de interpretación y análisis, como las que ofrece la inteligencia artificial.

Este tipo de estrategias están mal vistas por la opinión pública: se considera que manipulan los mercados, que tienen ventajas notorias frente al pequeño inversor (de conexión y computacional), que su finalidad es puramente especulativa, y finalmente porque son capaces de mover los mercados de forma muy peligrosa.

Prueba de esto último son los famosos *flash crash*, periodos cortos de tiempo donde el precio de un activo puede caer bruscamente en cuestión de minutos, para luego recuperarse inmediatamente. Uno de los más conocidos es el que se produjo en el Dow Jones el 6 de mayo de 2010 donde sufrió una caída del 9 por 100 de su cotización para prácticamente recuperar su valor inicial en apenas quince minutos (19).

Sin embargo, frente a esta corriente contraria a este tipo de *trading* están los que ponen encima de la mesa las ventajas que aportan: en gran medida son creadores de mercado que dan liquidez en ciertos momentos de mercado y para activos ilíquidos.

Según datos de la consultora TABB Group el *trading* de alta frecuencia supone el 41,5 por 100 de todas las operaciones que se efectúan en el mercado. Del resto de operaciones, un 15 por 100 serían efectuadas en base a modelos matemáticos y estadísticos, un 16,5 por 100 por *hedge funds*, y el 26,5 por 100 en base a criterios convencionales (fundamentales).

### *Inteligencia artificial: dos vertientes*

Las aplicaciones de la inteligencia artificial en el *trading* presentan dos vertientes: en la interpretación del dato y en la toma de decisiones.

Volviendo al caso real que hemos visto al inicio del artículo, quedó claro que el hecho de disponer de información y ser capaz de interpretarla antes que nadie puede darnos una ventaja competitiva muy lucrativa frente al mercado. Sin embargo, la inteligencia artificial juega un papel trascendental en dos ámbitos: primero en la interpretación del comunicado y del tuit, y posteriormente en la toma de decisión de compra y venta posterior.

Si bien en la interpretación del comunicado y del tuit podemos afirmar con rotundidad que en ambos casos son mensajes negativos para lo que el mercado estaba esperando, y en este sentido puede considerarse factible desarrollar un algoritmo que sea capaz de detectarlo (20), en el caso de la reacción del mercado, el algoritmo estaría haciendo una predicción futura sobre cómo los mercados reaccionarán, donde la incertidumbre es mayor.

Aunque en el ejemplo anterior pudiese parecer obvio que ante una noticia así los merca-

dos se iban a desplomar, esto no siempre ocurre: a veces, el mercado reacciona de forma inesperada (21). Por este motivo, a pesar de las grandes facilidades que la tecnología, el *big data* y las nuevas metodologías de *machine learning* ofrecen a la industria de gestión, debemos reflexionar si realmente tenemos hoy en día ante nosotros las herramientas para encontrar el santo grial o tenemos más medios para concluir, con más evidencias, que los mercados son aleatorios e impredecibles.

### *La máquina frente al gestor*

Sobre la incógnita de si los mercados son predecibles o no, la teoría del paseo aleatorio, contemplado por Burton G. Malkiel en su obra *Un paseo aleatorio por Wall Street*, nos viene a cuestionar la validez de cualquier tipo de información que podamos obtener del propio valor, siendo un sinsentido enfocar nuestros recursos y esfuerzos en buscar información que realmente aporte valor a nuestro estilo de gestión. Su autor, reconocido economista, escritor y profesor, plantea que los mercados son eficientes, incluyendo en su precio cualquier tipo de información existente, por lo que cualquier estrategia que no sea *buy and hold* (22) de una cartera que replique los mercados de una forma diversificada, no justificaría sus costes, ya que ninguna otra estrategia activa (técnica, fundamental o discrecional) consigue batir de una forma estable a los mercados.

Evidentemente, si consideramos que los mercados son aleatorios o simplemente caóticos, cualquier esfuerzo en intentar parametrizar o reconocer ciertos patrones de comportamiento, sería una pérdida de tiempo,

independientemente de que utilicemos las mejores bases de datos, dispongamos de ellas en tiempo real o dispongamos de las últimas y más desarrolladas metodologías de *machine learning*. Sin embargo, si consideramos que existen ciertos patrones que se repiten a lo largo del tiempo, o que existen relaciones estadísticamente representativas entre diferentes variables, podríamos desarrollar algoritmos que concediesen al gestor una ventaja frente al mercado, y podría sacar provecho de ella.

Los mercados financieros consisten en la confluencia de innumerables participantes, con intereses, objetivos, necesidades, limitaciones, conocimientos, información, experiencia y un largo etcétera, muy heterogéneos, lo que provoca que las transacciones y sus valoraciones de los activos puedan ser muy diferentes y cambiantes a lo largo del tiempo. Independientemente de la discusión que podamos tener sobre la diferencia entre precio y valor (23), el precio de las cosas es algo objetivo y el valor subjetivo, sin embargo, el valor (subjetivo) de las cosas es lo que determina el precio (objetivo) que los participantes están dispuestos a ofrecer o demandar por los activos.

Siguiendo esta línea argumental, lo cierto es que entonces no puede negarse que los mercados tienen cierto grado de aleatoriedad. Pero tampoco puede negarse que se producen ciertos patrones detectables en la evolución de los precios de los mercados: los precios se crean por la confluencia de oferta y demanda según valoraciones, como decíamos, subjetivas, donde la psicología y las emociones humanas juegan un papel clave en su formación, y el ser humano, en su

comportamiento, presenta constantemente patrones repetitivos. Ni tampoco puede negarse que existan relaciones entre variables en las que se pueda acreditar una conexión causa-efecto (como en el ejemplo inicial del comunicado y el tuit), o simplemente que existan ciertas ineficiencias en la formación de precios, aunque mínimas, arbitrables (24).

Es decir, a diferencia de lo que considerábamos con el ajedrez y el Go, donde todas las posibilidades eran teóricamente calculables, en los mercados financieros no, no hay casillas ni fichas finitas, ni como con Jeopardy, donde la interpretación del lenguaje tiene un menor grado de relatividad, pero ello no implica que no existan oportunidades.

En definitiva, siempre pueden producirse ciertas circunstancias no parametrizables ¿podría una máquina anticiparse o prever las posibles consecuencias de una guerra nuclear que nunca ha ocurrido? Sin embargo, hay evidencias de que se producen en los mercados ciertas circunstancias o patrones que se repiten de forma repetitiva a lo largo del tiempo de una forma estadísticamente representativa, o ciertas informaciones que condicionan directamente el valor de los activos, concediendo cierta ventaja si se conocen con anterioridad (sin referirnos a *inside trading* [25]), o existen, aunque cada vez menos debido al desarrollo de los mercados, ciertas oportunidades o arbitrajes escondidos entre valoraciones de mercado.

## VI. CONCLUSIONES

Tal como comenzábamos el artículo, un simple mensaje publicado en una red social es

capaz de arrastrar los mercados casi un 2 por 100 es cuestión de minutos, por lo que un inversor institucional no puede permitirse el lujo de no disponer de esta información de forma inmediata. Esta necesidad es la que está provocando en los mercados financieros el auge de técnicas de gestión cuantitativas basadas principalmente en tecnología, *big data* e inteligencia artificial.

A la espera de una nueva era tecnológica con la llegada de la informática cuántica, en los últimos años estamos siendo testigos de incrementos exponenciales de las capacidades computacionales y de almacenamiento, y de nuevas soluciones informáticas virtuales distribuidas, que han incrementado las posibilidades de la industria financiera, alcanzando cotas inimaginables hace años.

Vivimos en una época donde, de forma continua, las personas, los negocios y las propias máquinas están continuamente generando datos e información. La cristalización del fenómeno *big data* está facilitando la aparición de múltiples proveedores capaces de ofrecer esta información de forma legible para la industria en tiempo real y con ello posibilitando a los gestores nuevas herramientas de decisión.

La inteligencia artificial se ha vuelto clave en este punto, puesto que estas inmensas cantidades de información han de ser tratadas y posteriormente analizadas de forma automática, por lo que el desarrollo de sistemas basados en *machine learning* capaces de efectuar esta tarea al instante, se ha vuelto imprescindible. Del mismo modo, se hacen imprescindibles la elaboración de sistemas automáticos de *trading*

que de forma inmediata adopten decisiones de inversión, y aprovechen las oportunidades que el *big data* ofrece, y aquí, de nuevo, el *machine learning* juega un papel clave.

Con ello, cada vez es más habitual ver estadísticas con porcentajes muy elevados de operaciones efectuadas por máquinas en lugar de personas, sistemas robotizados que participan en los mercados de forma automática, cruzando órdenes contra otros sistemas. Sin embargo, pese a lo que podamos pensar, no estamos cerca de lo que se denomina singularidad tecnológica (26).

Constantemente hay evidencias de que el ser humano está detrás de los grandes movimientos de los mercados. Warren Buffet, considerado por muchos como el mejor inversor de la historia, y no habiendo utilizado inteligencia artificial en sus decisiones, tiene una frase célebre sobre los mercados de valores, definiéndolos como «maniaco-depresivos». Esto lo justifica con que puntualmente los mercados reaccionan bruscamente sin ninguna base lógica, tan solo dejándose llevar por la euforia y el pánico, emociones intrínsecamente humanas. De ahí que sigan creándose y explotándose burbujas como la de las criptomonedas del pasado ejercicio, o de las «sorprendentes» reacciones del mercado ante acontecimientos tales como el referéndum del *brexit*, que marcaron pérdidas históricas iniciales para recuperarlas en mes y medio, o el desplome inicial de los mercados ante los primeros sondeos que daban la victoria a Donald Trump, para terminar la sesión con ganancias cuando se confirmó la noticia.

También debemos tener en cuenta que la estrategia más extendida a nivel global es la que señalábamos al comienzo del artículo, de *buy and hold*, es decir estrategias de inversión cuya finalidad es invertir y mantener la posición en los mercados, estrategias no muy activas en su operativa, más allá de rebalances o coberturas.

En definitiva, podemos concluir que la inteligencia artificial se ha hecho un hueco en los mercados financieros como una herramienta imprescindible en la industria de inversión, por lo que su uso se generalizará con seguridad en los próximos años. Sin embargo, la inteligencia artificial difícilmente sustituirá al gestor humano totalmente, sino que, salvo casos puntuales de entidades muy especializadas, en general lo complementará en su toma de decisiones o se empleará como instrumento para crear estrategias colaterales a la inversión principal.

## NOTAS

(1) Por dar una proporcionalidad a este dato, el índice VIX, que representa la volatilidad o movimiento esperado del índice S&P 500 en un año, está en niveles en torno a 18, lo que quiere decir que, en once minutos, el índice tuvo el 10 por 100 del movimiento esperado por el mercado para un año entero.

(2) *Buy side* hace referencia a las entidades financieras que adquieren servicios o productos financieros, tales como fondos de inversión o pensiones, compañías de seguros, *hedge funds*, etcétera.

(3) La *beta* de mercado hace referencia a que, de una forma mayoritaria, las estrategias de inversión de la industria han seguido la evolución de los mercados de una forma cuasipasiva, por lo que sus rentabilidades y riesgos han venido determinados por los mercados en sí y no tanto por las decisiones de los gestores.

(4) El término *big data* hace referencia a grandes y diferentes conjuntos de información que aumentan a tasas cada vez mayores. Incluye tres aspectos claves: el volumen de

información, la velocidad a la que se crea y recopila, y la variedad o alcance sobre los datos que incluye.

(5) Este pronóstico se hizo realidad en la década siguiente, y en 1975, con más información, revisó la estimación del período de duplicación a veinticuatro meses. Por aquel entonces, los componentes también permitían duplicar la velocidad del chip, ya que la mayor cantidad de componentes podía realizar operaciones más potentes y los circuitos más pequeños permitían velocidades de reloj más rápidas.

(6) Ya son muchos los proveedores tecnológicos que emplean esta metodología (en el caso de Google, por ejemplo, emplea aproximadamente 1.000 ordenadores de forma paralela para dar respuesta a sus servicios).

(7) Se estima que en la actualidad el mercado de *big data* representa aproximadamente 130.000 millones de dólares americanos, cifra que se espera que alcance los 200 en el año 2020. La industria financiera es uno de los grandes participantes, representando aproximadamente el 15 por 100 del total, según estimaciones de JP Morgan.

(8) Con el término *quant* se hace mención a los profesionales expertos en el análisis y gestión de información cuantitativa. En la industria financiera desempeñan un papel crítico ya que reúnen amplios conocimientos estadísticos y matemáticos, y por otro lado conocimientos en diferentes lenguajes de programación.

(9) Como sentimiento de mercado se considera la opinión generalizada de los inversores sobre un activo o mercado. El sentimiento de mercado condiciona en gran medida la evolución de los precios de los activos y suele tener un componente emocional muy importante.

(10) *Alfa* es considerada la rentabilidad que puede aportarnos como inversores independientemente de la evolución de los mercados (esta última viene reflejada con la *beta* a la que previamente hacíamos alusión).

(11) Para estos casos suelen realizarse muestreos de información con los que se elaboran estudios estadísticos denominados *backtestings*, pero no siempre resultan concluyentes.

(12) Ratio financiera que mide la rentabilidad de una cartera por encima de la rentabilidad del *active* libre de riesgo, con respecto al riesgo (volatilidad) que se ha asumido para lograrla. Cuanto mayor sea la ratio, más atractiva es la inversión.

(13) El tamaño de la información depende en gran medida de la naturaleza del dato y el proveedor. Como referencia, los datos correspondientes a la información de mercado o ratios fundamentales. Existen históricos

de más de veinte años, datos procedentes de búsquedas web o noticias, hay históricos de quince años, procedentes de redes sociales de cinco años, y procedentes de sensores en torno a tres años.

(14) Abreviatura del término robot que se refiere a programas informáticos capaces de efectuar tareas concretas de forma autónoma y análoga a como las realizaría una persona.

(15) Conocido como algoritmo *minimax*.

(16) Aunque el ajedrez tiene un número de jugadas posibles cuantificable, es un número aún demasiado elevado como para poder utilizar estrategias que consideren todo el tiempo todos los casos posibles. En estos casos se emplean metodologías heurísticas.

(17) Este *software* fue desarrollado y liderado por David Silver, Aja Huang y Demis Hassabis.

(18) El término *trading* hace referencia a la operativa de compra y venta de activos financieros. Suele tener una connotación especulativa o cortoplacista, en contraposición con el término inversión.

(19) Aunque las causas del movimiento de mayo de 2016 se investigaron, no se llegó a ninguna conclusión. Tanto es así que se dice que fue provocado por lo que conocemos como *fat finger* en el que, al parecer, un analista de Citygroup se equivocó al pulsar sobre «B» de *billions* (miles de millones) en lugar de pulsar la tecla de «M» de *millions* en una negociación de acciones.

(20) Recordemos el ejemplo de Jeopardy, un algoritmo capaz de interpretar el lenguaje de las preguntas, y con ello, buscar respuestas.

(21) Un ejemplo muy llamativo se produjo en el año 2016, cuando se celebraban las elecciones presidenciales de EE.UU. entre Hillary Clinton y Donald Trump. Las encuestas previas daban ventaja a Hillary, sin embargo, con los primeros recuentos y ante la posibilidad de que Donald Trump ganase, los índices bursátiles cayeron en picado, para luego recuperarse y terminar subiendo, cuando se pasó de posibilidad a realidad.

(22) Estrategia de inversión consistente en comprar activos y mantenerlos en cartera a largo plazo.

(23) Una de las frases más célebres de Warren Buffet establece que el precio es lo que se paga por las cosas y el valor lo que se recibe de ellas. Sin embargo, existen inversores que consideran que no existe diferencia alguna entre precio y valor.

(24) Una operación de arbitraje consiste en la compraventa de un activo en dos mer-

cados distintos, aprovechando la diferencia de precio. Este tipo de operaciones permiten equilibrar los precios de los mercados hasta que desaparece la ineficiencia en la formación del precio.

(25) *Inside trading* hace referencia a la gestión de activos financieros en base a información privilegiada; en muchas legislaciones, es considerada ilegal.

(26) Con el término singularidad tecnológica hace referencia al momento futuro hipotético en el que la inteligencia artificial será autosuficiente y sustituirá al hombre de forma general en la toma de decisiones.

#### BIBLIOGRAFÍA

DAVEY, K. J. (2014). *Building Winning Algorithmic Trading Systems*. John Wiley & Sons, Inc.

ELDER, A. (1993). *Trading for a Living: Psychology, Trading Tactics, Money Management*. John Wiley & Sons, Inc.

GOODFELLOW, I., BENGIO, Y. y COURVILLE, A. (2016). *Deep learning*. MIT Press.

JOHNSON, B. (2010). *Algorithmic Trading and DMA: An introduction access Trading Strategies*. Barry Johnson.

LECUN, Y., BENGIO, Y. y HINTON, G. (2015). Deep learning. *Nature*, 521(7553), p. 436.

LIU, Y., ZENG, Q., YANG, H. y CARRIO, A. (2018). Stock Price Movement Prediction from Financial News with Deep Learning and Knowledge Graph Embedding. *Knowledge*

*Management and Acquisition for Intelligent Systems: 15th Pacific Rim Knowledge Acquisition Workshop, PKAW 2018, Nanjing, China, August 28-29, 2018, Proceedings*. Vol. 11016.

MALKIEL, B. G. (2019). *A Random Walk Down Wall Street*. W. W. Norton & Company.

MNIH, V., KAVUKCUOGLU, K., SILVER, D., GRAVES, A., ANTONOGLOU, I., WIERSTRA, D. y RIEDMILLER, M. (2013). Playing atari with deep reinforcement learning. *arXiv preprint arXiv:1312.5602*.

SUTTON, R. S. y BARTO, A. G. (1998). *Introduction to reinforcement learning* (Vol. 2, n.º 4). Cambridge: MIT Press.



## Resumen

La gestión de la identidad electrónica es clave para entender los servicios financieros del futuro, que tendrán un impacto global en un contexto multicanal. Las nuevas tecnologías y la regulación que ya las impulsa sitúan en el centro al cliente tanto para una mayor conveniencia como para oportunidades de contratación en el sector. El artículo ofrece una descripción de estas oportunidades y las ilustra con detalles y ejemplos prácticos.

*Palabras clave:* identificación electrónica, *know your customer* (KYC), biometría, contratación, identificación de clientes.

## Abstract

The electronic identity management is key to understand the future financial services whereas they will have a global impact and in a multi-channel context. The new technologies together with the new regulation boosting them, put the customer in the core of the financial business. The better convenience is bringing new business opportunities for the financial industry. This article offers a description of these opportunities and illustrates in detail and within practical examples.

*Keywords:* electronic identity, Know Your Customer (KYC), biometrics, customer identification.

*JEL classification:* G20, G28.

# LA IDENTIFICACIÓN ELECTRÓNICA: REDEFINIENDO LAS REGLAS DEL SECTOR FINANCIERO

Iván NABALÓN

CEO de Electronic Identification

## I. INTRODUCCIÓN

La gestión de la identidad electrónica es una pieza clave estratégica en el sector financiero. Es el principal elemento de generación de la confianza necesaria para el desarrollo de negocio en campos como los pagos o el crédito e ineludible a la hora de gestionar el riesgo de las operaciones, de prevenir el fraude y de cumplir con la regulación.

Su nivel de gestión adquiere mayor relevancia desde la entrada en juego del canal *online*, lo que ha creado múltiples oportunidades, pero también nuevas amenazas.

Las nuevas tecnologías de identificación electrónica: la identificación remota de clientes, la autenticación biométrica, la contratación, sumadas o impulsadas por las nuevas regulaciones hacen que este tópico se eleve al nivel de *game changer* del sector.

En este artículo describimos cómo las nuevas tecnologías y regulaciones están impulsando nuevas oportunidades de negocio en el sector financiero e ilustramos con ejemplos algunas de ellas.

## II. ¿QUÉ ES LA IDENTIDAD ELECTRÓNICA?

La identidad electrónica es el *alter ego* electrónico de una

persona. Toma especial trascendencia en un contexto de estilo de vida cada vez más digital y donde la confianza es clave a la hora de construir relaciones y evitar abusos y delitos derivados de un mal uso de esta.

Uno de los retos asociados a la gestión de la identidad electrónica es el de garantizar confianza en las transacciones en un medio como Internet, que por su naturaleza no lo hace. Otro de los retos es evitar el uso fraudulento o delictivo de la misma, así como garantizar derechos como la privacidad donde, de nuevo, por la naturaleza electrónica y la posibilidad de una memoria perdurable en el tiempo de este medio, puede desembocar en perjuicio para las personas.

### 1. Identificación vs. autenticación

Es importante diferenciar estos dos conceptos, pues a veces dan lugar a confusión.

*La identificación es el proceso de garantizar que la persona es quien dice ser.* El proceso comienza el día que el cliente inicia su relación con una institución financiera (IF) y se prologa todo durante un ciclo de vida hasta que deja de utilizar sus servicios. Cómo le registramos, cómo le vamos conociendo en el tiempo, cómo contrata y consume nuestros servicios. Todo esto es un proceso continuado donde

vamos conociendo al cliente e intentamos construir una relación de mutuo beneficio. En el argot del cumplimiento normativo y negocio financiero este proceso es conocido como *know your customer* (KYC).

La autenticación tiene como misión garantizar que la persona accede y consume nuestros servicios de base electrónica de una forma segura. La autenticación por sí misma no garantiza que la persona con la que interactuamos es quien dice ser, pero sí debe de garantizar que los mecanismos y/o secretos que usa para acceder a nuestras aplicaciones son seguros tanto para el acceso como para las transacciones financieras tales como: transferencias, pagos, contratación de créditos, etcétera.

Un ejemplo para ilustrar la diferencia entre estos conceptos:

Pongámonos en situación: una persona se compra un teléfono inteligente iPhone X, que incorpora la última tecnología biométrica. El usuario activa el servicio Apple Pay para incluir una de sus tarjetas de crédito expedidas por su banco habitual. Esto facilitará los pagos en tiendas minoristas, tales como: tiendas de ropa, cafeterías, clínicas, etcétera.

Comenzamos por la autenticación: la estrategia de autenticación de Apple es una estrategia multifactor. No ha cambiado desde los primeros modelos, ya que basa su seguridad en la contraseña para acceder al *Smartphone* como primer factor y, como segundo factor, aplica la biometría facial con su tecnología FaceID. Cuando el usuario compra su terminal, lo abre y se registra seleccionando una contraseña para su acceso y re-

gistrando su cara en el FaceID. Ambas quedan grabadas en el terminal de forma segura y el usuario accede habitualmente al terminal y a sus aplicaciones combinando estos dos métodos. Apple y, por extensión, su ecosistema de desarrolladores conoce que la persona que compró el teléfono es quien accede a las aplicaciones, pero ¿conocen la identidad de la persona? Y la respuesta es que solo con estos métodos no. Lo que pueden garantizar con estos métodos de autenticación es que la persona que se registró inicialmente accede al teléfono y a sus aplicaciones, pero no necesariamente la identidad real de la persona.

Cuando el usuario quiere activar su servicio Apple Pay (e-wallet) y por temas de confianza y cumplimiento normativo, Apple y sus socios financieros tienen la necesidad de identificar inequívocamente al cliente, hablaremos de identificación. ¿Y cómo lo hacen? Enlazando una cadena de confianza que tiene su origen en que la IF, dentro de sus procesos KYC y previo a dar de alta una tarjeta de crédito, ha tenido que conocer al cliente, identificarle, probablemente a través de su tarjeta de identidad o pasaporte en la oficina comercial, han firmado un contrato y, posteriormente, le ha proporcionado una tarjeta de débito o crédito con las credenciales para poderla usar. Cuando Apple permite al usuario activar el servicio Apple Pay a través de su tarjeta de crédito es cuando existe una vinculación entre una persona no necesariamente conocida y la confianza en la identidad que proviene de la IF y que por motivos regulatorios ha tenido que conocer la identidad real del cliente previamente. En todo este proceso esta presente la identificación.

¿Por qué la identificación? La respuesta es sencilla: confianza.

La confianza necesaria que es requerida hace siglos para realizar los negocios y la confianza para evitar un uso delictivo del capital.

¿Por qué la autenticación? La respuesta también es sencilla: por seguridad. La seguridad necesaria de conocer que las personas que supuestamente realizan las operaciones en el día a día son quienes dicen ser.

Como veremos más adelante en este artículo, en el sector financiero la combinación de un proceso continuado de identificación y una estrategia segura de autenticación son claves para la relación con nuestros clientes.

### III. NUEVAS TECNOLOGÍAS

Existen tres campos en los que las nuevas tecnologías, apoyadas por la nueva regulación, irrumpen con fuerza en el sector financiero para redefinir las reglas del juego en relación con los clientes y el negocio:

#### *La identificación remota de clientes*

En 2014 aparece por primera vez en la historia una autorización de procedimiento (BaFin, 2014) por un regulador para la identificación no presencial de clientes. El regulador es el alemán Bafin (Federal Financial Supervisory Authority). A través de una entrevista por videoconferencia que dura unos minutos el cliente puede abrir una cuenta o contratar un servicio sin límites económicos asociados, evitando personarse en las oficinas del banco. En 2016 el regulador español (SEPBLAC, Servicio Ejecutivo de la Comisión de Prevención del Blanqueo de Capitales e Infracciones Monetarias) es pionero también en liberar un procedimiento de

identificación no presencial que permite identificar remotamente a los clientes con un sistema de videoidentificación. La videoidentificación es exactamente igual de segura que la entrevista por videoconferencia, pero se realiza en dos pasos: 1) el usuario se registra en unos segundos por un vídeo en *streaming* en un proceso controlado por el banco; 2) una persona cualificada verifica más tarde las pruebas. Este proceso es más sencillo y conveniente para el usuario y más eficiente y escalable para el banco.

Con el tiempo, el vídeo en *streaming* se ha convertido en la tecnología estándar para más de 38 países en el mundo (Nabalón, 2019) y con planes para que antes de que termine 2020 se haya instaurado como estándar en más de 55 de las principales economías mundiales.

Este acontecimiento, del que hablaremos en detalle más adelante, es uno de los principales disruptores en el campo de la identificación electrónica en el sector financiero, ya que permite la realización de los negocios en un contexto totalmente digital y, por tanto, transfronterizo y global, sin la necesidad de estructuras físicas como oficinas comerciales que han sido necesarios en la historia de la banca.

### Autenticación biométrica

La biometría, o lo que es lo mismo, la medición y aprovechamiento de las características físicas de las personas, como pueden ser: las huellas dactilares, la forma de la mano, el patrón de las venas, la retina o la forma de la cara, amplían la forma en la que un usuario puede ser autenticado, más allá de las viejas e inconvenientes contraseñas.

| TIPO DE BIOMETRÍA  | CANALES NO PRESENCIALES |          |            | CANAL PRESENCIAL     |
|--------------------|-------------------------|----------|------------|----------------------|
|                    | MÓVIL                   | WEB      | TELEFÓNICO | OFICINAS COMERCIALES |
| <b>Facial</b>      | Adecuado                | Adecuado | Nulo       | Adecuado             |
| <b>Dactilar</b>    | Adecuado                | Nulo     | Nulo       | Limitado             |
| <b>Iris/retina</b> | Limitado                | Limitado | Nulo       | Limitado             |
| <b>Voz</b>         | Adecuado                | Limitado | Adecuado   | Adecuado             |

Los mecanismos de autenticación biométrica ofrecen nuevas formas para facilitar la contratación con el cliente, adaptándose a sus necesidades y al canal donde operan, haciendo una experiencia de contratación e iteración con los servicios más sencilla y, por tanto, promoviendo e impulsando las ventas en el sector, especialmente en lo referente a los pagos y al crédito.

### Firma electrónica cualificada

La firma electrónica es el concepto jurídico equivalente al proceso analógico de firma manuscrita que tiene como objetivo que los acuerdos entre el cliente y la IF queden suscritos electrónicamente, de una forma segura, inalterable y demostrable en cualquier momento ante terceros en caso de un problema o repudio en la contratación por alguna de las partes.

La contratación a través de la firma electrónica es un concepto ya extendido y ampliamente aceptado en prácticamente la totalidad de países. Sin embargo, ha tenido muchas limitaciones dependiendo del nivel de riesgo del contrato. Mientras su uso se ha hecho común en contratos de bajo riesgo como pólizas de seguros de coche, hogar o microcréditos, el uso en contrataciones de alto riesgo, tales como: hipotecas, créditos de alto riesgo, seguros de vida o planes de pensiones, entre otros, ha sido prácticamente nulo.

La razón es que existen distintos tipos de validez jurídica de las firmas, y las de mayor validez (equivalente a la manuscrita) o no han sido posibles en un contexto 100 por 100 digital o la usabilidad de las soluciones (por ejemplo, el DNI electrónico) son muy bajas y, por tanto, su uso escaso.

La nueva regulación eIDAS, junto con las nuevas tecnologías de firma centralizada, crean un concepto de firma de alto nivel, denominado firma electrónica cualificada, que es equivalente en eficacia a la firma manuscrita. Se puede realizar de inicio a fin en un contexto digital y permitirá abordar procesos de contratación o nueva contratación de los ya mencionados servicios de alto riesgo. Y todo de una forma sencilla y conveniente para el usuario. Este hecho abre oportunidades para todas las IF facilitando la contratación de servicios en un contexto global, multicanal y de forma conveniente para el usuario.

La siguiente imagen describe los distintos tipos de firma, incluyendo la nueva firma electrónica cualificada.

En conclusión, con las nuevas tecnologías de identificación electrónica la identificación remota de clientes, la tecnología biométrica y las nuevas firmas electrónicas, hacen posible cambiar las reglas del juego, ofreciendo mayores posibilidades de negocio tanto de nuevos servicios como de nuevos territorios y, además,

|                        | Identificación del firmante | Canales                    | Dispositivo           | Equivalencia con manuscrita | Nivel de riesgo      |
|------------------------|-----------------------------|----------------------------|-----------------------|-----------------------------|----------------------|
| e-Signature            | NO                          | ONLINE, OFICINA Y TELÉFONO | CUALQUIER DISPOSITIVO | NO                          | Bajo                 |
| Advanced e-Signature   | SI                          | ONLINE, OFICINA            | CUALQUIER DISPOSITIVO | NO                          | Alto                 |
| Qualified e-Signature* | SI                          | ONLINE, OFICINA            | CUALQUIER DISPOSITIVO | SI                          | Alto, Admon. Pública |

mejorando la experiencia para una contratación mucho más efectiva y conveniente.

#### IV. EL IMPACTO GLOBAL Y MULTICANAL

«El futuro del sector bancario pasará por desarrollar una oferta global de servicios y en un contexto multicanal».

A mediados de esta década nacen N26, Revolut y otros neobancos y *fintechs*. La idea que toma forma es que el mundo y la prestación de servicios financieros será completamente *online* y obviamente global.

En la otra cara de la moneda tenemos a las entidades más tradicionales: estas han sufrido en las últimas dos décadas un proceso de concentración, racionalización y globalización, y se inclinan, en general, por hacer justamente todo lo contrario: su objetivo es adaptarse a las circunstancias de cada país, haciendo un esfuerzo por parecerse a lo local, con una estrategia donde las decisiones son cada vez más situacionales y sin un ánimo de globalizarse, al menos como una iniciativa única. Podemos decir que HSBC o Citibank son bancos globales, pero la realidad es que son la suma de muchos bancos locales. Quizá aprovechen sinergias, tengan buenas prácticas comunes, pero no existe un servicio a un cliente estándar que funcione de forma semejante cambiando de un país a otro y,

por lo general, mantienen una soberanía y autonomía local. Y, aunque avanzan en lo digital, gran parte de su negocio se realiza todavía en presencia en las oficinas comerciales.

Este modelo que se comienza a establecer a inicios de esta década también está cambiando: en los últimos años se observan movimientos donde las *fintech* desarrollan o llegan a acuerdos con terceros para ofrecer servicios en espacios de *retail* físico: tenemos muchos ejemplos en el ámbito de los pagos y también en el crédito. Por ejemplo, por un lado, Pagantis, una *startup* de origen español, con una última ronda de financiación de 65 millones de euros, y que tiene éxito con uno de sus principales negocios en la financiación al consumo en alianzas con empresas minoristas que tienen presencia física, más allá del comercio electrónico. Y, en el otro lado, por la puesta digital de los bancos: podemos ver, por ejemplo, como bancos como CaixaBank lideran el *ranking* de clientes digitales y mejores aplicaciones bancarias en la región (1).

*¿Qué está pasando?*  
*¿Nos movemos de extremo a extremo? ¿Convergeremos?*

Existen datos objetivos que muestran que el gran grueso de las transacciones en el día a día se realiza todavía presencialmente (*offline*). Y ¿por qué? Es simple: la vida de las personas tiene un componente físico y so-

cial y es difícil que desaparezca. Podremos digitalizar y facilitar muchos procesos, pero seguiremos yendo a la clínica dental a realizarnos un implante, tomaremos una cerveza o un café, un avión o un coche para viajar, dormiremos en un hotel o visitaremos un evento profesional. Y todos estos procesos necesitarán de servicios financieros: pagos, crédito, seguros...

Y dicho esto, considero que las conexiones de los canales para ofrecer servicios serán un reto para que los bancos tradicionales mejoren lo *online* y el servicio global; y las *fintech* toquen suelo y creen ecosistemas de negocio para los negocios presenciales. Es muy probable que las estrategias converjan con el tiempo.

Si miramos el ámbito *retail* vemos ejemplos como Amazon (el *e-commerce* lleva años de adelanto al sector financiero y nos podemos fijar en él). Amazon está conectando el mundo digital y el presencial con adquisiciones como la de la cadena de supermercados Whole Foods o la más reciente inversión en Deliveroo, el disruptor de la entrega a domicilio.

Algunos podrán decir que estos últimos movimientos son para dominar la última milla. Otros verán la necesidad de conectar clientes con servicios multicanal, para fortalecerse. Mi opinión es que la suma real de una estrategia multicanal es mayor que una *online* y *offline* separadas.

*Hacia un consumo seamless*

Soy fan de la serie de HBO *MadMen* y del *marketing* de los años 50 y 60. En un capítulo de la temporada cinco el gurú del *marketing* Don Draper crea un concepto llamado *Sales Carousel* en el que vende la idea de un



consumo de producto sistemático y sin fricciones. ¡Me encanta!

Me inspiro en este concepto para explicar a mis alumnos y clientes lo que pueden hacer con las nuevas tecnologías: identifícate una vez, consume y contrata múltiples servicios, sin fricciones, todo el tiempo, en cualquier canal.

Y un dato para ilustrar cómo crece la contratación cuando el servicio se piensa para una experiencia *seamless*: un estudio reciente de AT Kearney (2) muestra un dato espectacular: desde que Apple incorpora el FaceID (autenticación biométrica facial) en sus iPhone, el usuario de *wallet* para pagos ha incrementado su uso en un 45 por 100. Y esto solo en un año. No solamente creo en lo que dice este estudio, sino que lo refrendo como consumidor. Mi *iPhone* hace que yo no necesite *cash* más de cuatro o cinco días al año, y esto solo sucede cuando necesito sacar dinero para pagar o adelantar dinero a algún amigo algo ya que en España todavía no existe una solución digital que me permita hacerlo. Para el resto: desde pagar un café, hasta una comida, taxi o cualquier otra necesidad, utilizo mi móvil como cartera.

Como resumen, es importante pensar en estrategias con la adopción de nuevas tecnologías que permitan contratar de una forma sencilla, en cualquier momento, en cualquier canal y con una experiencia perfecta y conveniente para el cliente.

## V. LA REGULACIÓN

Debemos fijarnos en las nuevas regulaciones europeas para analizar y comprender las oportunidades que se presentan en nuestro sector, no solo en Europa, sino

también a nivel global, ya que las bases de estas regulaciones, en las que la Comisión Europea lleva trabajando años, están siendo trasladadas a otras regiones como Asia, Oriente Medio y Latinoamérica. De hecho, incluso algunos países anglosajones, donde el tratamiento de la privacidad de las personas o los servicios de confianza han sido tratados con muchas carencias por el derecho civil común (*common law*), están haciendo acopio del trabajo para construir sus propias guías y procedimientos. Estamos hablando de países como EE.UU., el Reino Unido o algunos pertenecientes a la *Commonwealth*.

Regulaciones como la nueva directiva de Prevención de Blanqueo de Capitales y Financiación del Terrorismo, comúnmente denominada AML5, la regulación en pagos y banca abierta, PSD2, en privacidad, GDPR, y en servicios de confianza electrónica el comúnmente denominado eIDAS, son algunas de ellas.

De forma particular, estas normativas están evolucionando o creando conceptos que ya permiten a los bancos la adopción de nuevas formas de interactuar con el cliente y generar nuevos negocios: identificación remota, autenticación reforzada de cliente, contratación de alto nivel de riesgo, etc.; de forma conjunta, unas se conectan con otras para crear verdaderas oportunidades regionales. Por ejemplo, a falta de un esquema específico de seguridad, la nueva directiva AML5 delega en el marco eIDAS de servicios de confianza todas las cuestiones relacionadas con los procesos de identificación remota y contratación. La conexión de PSD2 con eIDAS permite ofrecer un marco de seguridad para la autenticación de los clientes y

su portabilidad. Si observamos todas juntas, las nuevas regulaciones son un *game changer* en el sector financiero.

En Europa se crea, por primera vez en la historia, el concepto de Mercado Único Digital (MUD). El MUD estandariza la identidad electrónica para todos los países miembro, del mismo modo que el euro hizo con las monedas a principios de este siglo. Esto habilita a que las empresas puedan hacer negocios en la segunda economía mundial con 20 billones de euros de PIB y con acceso a un mercado de 508 millones de consumidores. Este acceso más homogéneo al mercado elimina diferencias fundamentales para realizar los negocios, como ocurre en mercados transnacionales maduros como el de Estados Unidos de América con leyes federales que estandarizan el mercado. Significa un tremendo potencial para el crecimiento de nuestra economía.

### Novedades regulatorias en la identificación remota

Hasta la llegada de la primera normativa en el mundo, que se liberó en Alemania en 2014, la única forma de identificar a un cliente con todas las garantías que requiere la contratación de alto riesgo o la apertura de cuentas en el sector financiero se realizaba en presencia, cara a cara en la oficina comercial de la institución financiera.

Esta normativa pionera en Alemania, que permite a las IF identificar a los clientes digitalmente y de forma remota por una entrevista por videoconferencia, marca un antes y un después en las relaciones a distancia por el canal digital. El proceso consiste en una entrevista que realiza un



agente cualificado con el cliente: durante la entrevista el agente verifica la identidad a través de un documento expedido por un estado miembro (tarjeta de identidad o pasaporte). Se verifica la autenticidad del documento a través de las medidas de seguridad, valida que la persona está viva y que su identidad corresponde con la del documento. La entrevista se graba como principal evidencia de este acto de identificación y posterior a la misma, la IF realiza el resto del proceso KYC y, con todo en orden, finalmente procede a la creación de la cuenta o a la contratación.

Previo a este hito normativo ya existía tecnología de validación de documentos, fundamentalmente fabricantes de *software* anglosajones que permitían realizar y tratar fotografías o documentos de identidad escaneados (denominados *selfies*), los comparaban con un pequeño *streaming* de vídeo de la cara del cliente y realizaban lo que se denomina una acreditación de identidad. Como veremos más adelante, estas soluciones de *selfies* que tratan imágenes (no video) nunca ofrecieron una seguridad equivalente a la personación. Se utilizaban y se siguen utilizando para procesos de verificación de un menor riesgo, como, por ejemplo, en la contratación de pólizas de coche, seguros de hogar o microcréditos.

Con la circular del BaFin alemán, el estándar de seguridad para el nivel de seguridad equivalente a la personación cara a cara se establece en la tecnología de vídeo en *streaming* y en la validación por un humano entrenado.

Este hecho da lugar, eventualmente, a la aparición de los primeros neobancos, como es el

caso de Number 26 (ahora N26), uno de los principales bancos puramente digitales a nivel mundial con una valoración que supera los tres billones de dólares y que marca el camino a otras muchas *fintech* o *insurtech* que eventualmente se quieren convertir en un prestador de servicios financieros puro y regulado. Bancos como N26 hacen publicidad como los primeros bancos digitales, ofreciendo una cuenta IBAN y una tarjeta de crédito. Su punto fuerte es que ya no necesita ningún canal presencial, ofrece a sus clientes un servicio puramente digital, incluido el proceso de alta, que es la estrella de esta película.

Esta normativa es copiada ampliamente en países de Europa, Latinoamérica, Asia, incluso EE.UU. Los beneficios son claros ya que mejoran la experiencia del cliente (ya no tiene que ir a la oficina comercial). Sin embargo, es problemático a la hora de escalar porque es un proceso muy complejo: más de diez minutos, técnicamente problemático: dos comunicaciones (voz y vídeo) bidireccionales que dan muchos problemas y, finalmente, complejo porque tiene una limitación importante en el número de personas que la IF puede entrenar y en sus costes, al tener que mantener un equipo que tiene que estar siempre disponible, pero no siempre utilizado.

En marzo de 2016, el regulador en España SEPBLAC da un paso para optimizar este proceso y lanza un procedimiento de identificación no presencial por vídeoidentificación, manteniendo la seguridad de la circular del BaFin, pero permitiendo un proceso asíncrono, donde el cliente se identifica en un proceso grabado de vídeo que dura unos segundos y más tarde un agente cualificado verifica las pruebas del registro y valida la identidad. El proceso de registro mejora la experiencia de cliente: se identifica en segundos, mejora los ratios de adquisición de cliente por la facilidad del método y aumenta la escalabilidad, ya que se optimiza el tiempo de verificación en la parte de los agentes sin restar en seguridad.

A junio de 2019, contabilizamos más de 38 países que permiten sistemas basados en vídeo en *streaming* y la verificación por un humano cualificado como estándar para la identificación remota de clientes en la industria financiera. Por las conversaciones con reguladores y bancos en otros países, estimamos que sean más de 54 los países que de una forma u otra lo adopten hasta final de año.

La lista de países por región, a día de hoy, es la siguiente:

| REGIÓN            | NÚM. DE PAÍSES | NOTA                                                      |
|-------------------|----------------|-----------------------------------------------------------|
| Europa            | 28             | Todos los Estados miembros de la Unión Europea            |
| América del Norte | 1              | Estados Unidos de América                                 |
| América del Sur   | 3              | Brasil, México, Colombia                                  |
| Asia              | 5              | Armenia, Hong Kong, Japón, Singapur, Corea del Sur, India |
| Otros             | 1              | Suiza                                                     |

|                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                     |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                  |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                            |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <p>Esta estandarización se apun-<br/>tala adicionalmente con dos he-<br/>chos:</p> <p>El GAFI (Grupo Acción<br/>Financiera Internacional) incluye<br/>la identificación a distancia en<br/>sus recomendaciones en diciem-<br/>bre de 2016.</p> <p>La Comisión Europea estable-<br/>ce un reglamento de ejecución<br/>2015/1502 que establece los ni-<br/>veles de seguridad en la identi-<br/>ficación electrónica. El reglamento<br/>de ejecución es una extensión de<br/>la regulación eIDAS 910/2014,<br/>en vigor desde julio de 2016,<br/>que establece la norma comuni-<br/>taria de obligado cumplimiento<br/>y aplicación directa para todos<br/>los Estados miembros en lo rela-<br/>tivo a los servicios de confianza<br/>electrónica, que, entre otros,<br/>regula la identificación y la firma<br/>electrónica para las relaciones<br/>digitales. Esta regulación permite<br/>que los fabricantes y prestadores<br/>puedan certificar sus soluciones<br/>de identificación electrónica a<br/>través de un laboratorio cualifi-<br/>cado por la Unión Europea. Estos<br/>laboratorios se denominan <i>con-<br/>formity assessment bodies (CAB)</i><br/>para el eIDAS.</p> <p>Por último, y como hecho re-<br/>levante para la industria finan-<br/>ciero, la liberación de la Quinta</p> | <p>Directiva Europa de Prevención<br/>de Blanqueo de Capitales (AML5)<br/>en mayo de 2018, que confía en<br/>el marco de seguridad del eIDAS<br/>la identificación de clientes y<br/>medidas de diligencia debida a<br/>sujetos obligados, no solo ho-<br/>mogeneizando las soluciones en<br/>Europa, sino también liderando<br/>la regulación AML, que abre la<br/>puerta a las iniciativas <i>fintech</i>,<br/>como, por ejemplo, las monedas<br/>virtuales.</p> <p><i>¿A quién afecta esta regulación<br/>en el sector?</i></p> <p>La adopción de este conjun-<br/>to de medidas para la identi-<br/>ficación remota afecta, a modo<br/>de resumen, a distintos tipos de<br/>entidades, ya sean entidades con<br/>negocios tradicionales o enti-<br/>dades basadas en la tecnología<br/>(<i>fintech e insurtech, ITFs...</i>). La<br/>denominación de estas puede<br/>variar de un país a otro.</p> <ul style="list-style-type: none"><li>– Las entidades e instituciones<br/>de crédito.</li><li>– Las sociedades gestoras de<br/>instituciones de inversión<br/>colectiva y las sociedades de<br/>inversión cuya gestión no esté<br/>encomendada a una sociedad<br/>gestora (sociedades finan-<br/>cieras populares, sociedades<br/>financieras comunitarias, or-</li></ul> | <p>ganismos de integración fi-<br/>nanciera rural...).</p> <ul style="list-style-type: none"><li>– Las entidades aseguradoras<br/>autorizadas para operar en el<br/>ramo de vida y los corredores<br/>de seguros cuando actúen en<br/>relación con seguros de vida<br/>u otros servicios relacionados<br/>con inversiones.</li><li>– Las empresas de servicios de<br/>inversión.</li><li>– Las entidades gestoras de<br/>fondos de pensiones.</li><li>– Las sociedades gestoras de<br/>entidades de capital-riesgo<br/>y las sociedades de capital<br/>riesgo cuya gestión no esté<br/>encomendada a una sociedad<br/>gestora.</li><li>– Las sociedades de garantía<br/>recíproca.</li><li>– Las entidades de pago y las<br/>entidades de dinero electró-<br/>nico.</li></ul> <p><i>Niveles de seguridad en la<br/>identificación remota digital</i></p> <p>Todas las regulaciones AML<br/>conocidas establecen tres niveles<br/>de seguridad en la identificación<br/>remota, que son los siguientes:</p> |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|

| NIVEL DE<br>SEGURIDAD | DESCRIPCIÓN                                                                                                                                                                                                                 | CASOS DE USO                                                                                                                                            | SISTEMAS                                                                                                                                                                   |
|-----------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Bajo                  | La confianza requerida de que la persona es quien dice ser es baja. El nivel de seguridad puede ser comprometido con facilidad. El daño causado en el proceso proveniente de una identidad comprometida debe de ser mínimo. | Comercio electrónico; no se usa en el sector financiero.                                                                                                | Asunción de la información proporcionada por el cliente; chequeos en el back con información pública del cliente; redes sociales.                                          |
| Medio                 | La confianza requerida de que la persona es quien dice ser es moderada. El daño causado en el proceso proveniente de una identidad comprometida podría ser moderado.                                                        | Contratación con riesgo bajo: coche, hogar, microcréditos.                                                                                              | Tecnología de verificación de la identidad a través de documentos por imágenes ( <i>selfies</i> ).                                                                         |
| Alto*                 | La confianza requerida de que la persona es quien dice ser es alta. El daño causado en el proceso proveniente de una identidad comprometida podría ser serio o catastrófico.                                                | Apertura de cuentas sin lites quien dice ser es alta. El daño causado mite, contratación riesgo alto: crédito >999 dólares, euros...? hipotecas, pagos. | (1) Personación cara a cara en la oficina comercial;<br>(2) entrevista por videoconferencia;<br>(3) videoidentificación con verificación posterior con agente cualificado. |

\* Tienen la necesidad de obtener una certificación por un organismo evaluador y certificador: *conformity assessment body (CAB)* dentro de las listas de confianza europeas.

### *Novedades regulatorias en la autenticación*

El concepto de autenticación reforzada de cliente (ARC) es un concepto que viene de la nueva regulación, principalmente de la categoría de pagos (PSD2), que es una de las más crecientes en esta explosión de regulaciones y nuevos servicios financieros.

La ARC es una estrategia de autenticación que se basa en el uso de dos o más elementos categorizados como: conocimiento (algo que solo el cliente conoce); posesión (algo que el cliente posee); y algo inherente al usuario (algo que el cliente es). Estos elementos son independientes, es decir, que el compromiso de uno no significa la falta de fiabilidad del otro. Las combinaciones múltiples de unos factores con otros ofreciendo la mejor experiencia en el uso al cliente define la estrategia de autenticación de cualquier IF.

Se estima (Capgemini y BNP Paribas, 2018) que el volumen de transacciones de pagos digitales (sin efectivo) creció en 2016 un 10,1 por 100 para alcanzar los 482,6 billones y que el volumen de transacciones para los pagos con carteras electrónicas (*e-wallet*) ya alcanza los 41,8 billones, siendo el 8,6 por 100 de todas las transacciones. Este crecimiento continuado en una economía que intenta eliminar la moneda física, sumado a la necesidad de prevenir el fraude, está siendo clave para que los bancos y *fintech* inviertan (KPMG, 2019) en nuevas tecnologías, incluyendo la inteligencia artificial para alertar sobre fraude en tiempo real, así como tecnologías de reconocimiento facial, voz y huellas dactilares (autenticación biométrica).

Y desde que, en mayo de 2016, el norteamericano National Institute of Standards and Technology (NIST) publica unas líneas base en las que recomienda el desuso de la autenticación por SMS como segundo factor de autenticación, los factores biométricos mencionados se están convirtiendo rápidamente en uso común en la industria.

### *Novedades regulatorias en la firma electrónica*

Las primeras leyes de firma electrónica datan de 1999, casi en paralelo a la creación de Internet. Sin embargo, no es hasta hace una década que su uso se comienza a generalizar.

Las primeras leyes de firma electrónica permiten el nacimiento en algunos países de los documentos nacionales de identidad electrónicos, que incluyen un certificado electrónico de persona física preparado para que las personas puedan identificarse y firmar un contenido electrónicamente con las mismas o mayores garantías que la firma manuscrita. Sin embargo, y dada la falta de experiencia de los técnicos y reguladores, la mayoría de estos proyectos acaban siendo un fiasco en todos los países debido a que la usabilidad de las soluciones (instalación de “chipeteras”; no funcionan en el móvil; certificados instalados con *plugins* en los navegadores) es muy baja, descargando la complejidad de estas en usuarios que necesitan ser avanzados tecnológicamente para hacerlos funcionar. El resultado es que después de una década, en el mejor de los casos, este tipo de firmas no llegan a usarse por más del 1 por 100 de la población. Aun así, la idea de un *alter ego* digital ofrecido por un prestador de servicios de

certificación y la posibilidad de contratar a distancia es una idea magnífica, eso sí, echada al traste por la falta de mecanismos que la hagan fácil de usar.

En todos estos años, como pasa en muchas ocasiones, alguien más pragmático ve una oportunidad e introduce la figura de la firma digital, basada en el derecho anglosajón y confiando en terceras partes de confianza (TPC) para intermediar en el proceso de contratación. Y son fundamentalmente los fabricantes y TPC norteamericanos los que permiten extender este tipo de firmas porque son fáciles de usar: el usuario solo necesita un correo electrónico y un teléfono móvil para firmar un documento. Sin embargo, tienen una limitación importante y es que su seguridad jurídica, como no identifican y vinculan de una forma segura al cliente (solo con su correo electrónico y su móvil, y no con una identificación de nivel alto) se acaban generalizando solamente para procesos de bajo riesgo, como, por ejemplo, las pólizas de un seguro de coche, de hogar o incluso algunos microcréditos. Las IF no son capaces de implantar sistemas en otro nivel de riesgo ya que pueden suponer un daño muy alto para las compañías. Hay que mencionar obviamente que estamos hablando del canal *online*, de contratación remota. En los espacios presenciales como oficinas comerciales, sí existen firmas de alto nivel dado que la identificación se realiza en presencia y aquí se extienden las firmas biométricas digitalizadas (grafobiométrico) por huella y equivalentes, que sí ofrecen un nivel de garantía suficiente.

Es la firma remota/*online*, la que continúa siendo un reto

para contrataciones de alto nivel de riesgo tales como: hipotecas, seguros de vida, crédito, pagos, etc... Y, en este sentido, y dada la aparición de las nuevas tecnologías como las mencionadas de videoidentificación, el avance en el ámbito legal también se ha producido, además con importantes novedades en el ámbito de la usabilidad, su principal freno años atrás.

En julio de 2016 entra en vigor en Europa la regulación eIDAS, como evolución de las antiguas leyes de firma electrónica. El eIDAS regula todos los servicios de confianza electrónica, cambiando la denominación

de los prestadores de servicios de certificación por prestadores de servicios de confianza y haciendo pequeñas modificaciones en la norma para que las firmas electrónicas de mayor nivel jurídico, las firmas electrónicas avanzadas, puedan ser utilizadas ampliamente con una usabilidad semejante a la que un usuario puede tener al usar una tarjeta de crédito: a través de un PIN o combinando con una contraseña de un solo uso que llega a su móvil. Evitando así las complejidades de las antiguas leyes.

eIDAS soporta los distintos tipos de firma: electrónica, avanzada y cualificada y permite que

cualquier tipo de contratación se pueda realizar en cualquier canal. Un paso importante para la digitalización de muchos procesos de contratación que hasta la fecha no eran posibles.

## VI. APLICACIONES DE LA IDENTIFICACIÓN ELECTRÓNICA

Esta sección trata de ilustrar algunos ejemplos, las oportunidades que trae consigo la adaptación de nuevas tecnologías de identificación electrónica:

### 1. La captación ubicua y transfronteriza de nuevos clientes



Ilustración 1. Proceso de identificación de cliente. Fuente: Electronic Identification.



Web



Mobile



ATMs/Kioscos  
con cámara



Branch Office, mediante  
el proceso digital



El proceso de hágase cliente en el canal online evoluciona con la nueva regulación para convertirse en la captación de clientes digital, multicanal y global.

De este modo, cualquier banco puede pensar en nuevas estrategias de captación de nuevos clientes y contrataciones en cualquiera de los países que lo

han regulado, cumpliendo con la legislación y los requerimientos más exigentes.

## 2. La contratación *seamless*

El nuevo modelo de firma electrónica, fácil de usar y adaptada a la conveniencia de los clientes, facilita la contratación, incluyendo ya procesos de alto

riesgo, tales como: hipotecas, seguro de vida, planes de pensiones o créditos.

Es importante pensar que el mismo modelo de firma eIDAS pueda ser utilizado con la mayor conveniencia y experiencia del cliente.

Algunos ejemplos:



Ilustración 2. Firma por OTP en el móvil



Ilustración 3. Firma con DNle en el móvil



Ilustración 4. Firma con grafo en un quiosco de una oficina comercial



Ilustración 5. Firma con la biometría de la cara en una tableta

## 3. Los pagos *seamless*

Los negocios dominantes en los pagos, como las redes de pago MasterCard y VISA o los monopolios emergentes en los pagos sin contacto como Apple Pay y Samsung Pay, son seriamente amenazados por un mo-

delo de seguridad centralizado propuesto en Europa por la PSD2 y el eIDAS.

Los cambios más importantes para habilitar este concepto vienen por la desaparición de los elementos materiales de los procesos, por ejemplo, las

tarjetas de crédito o los terminales punto de venta: la sustitución del *hardware* por *software* es un hecho. También vienen de eliminar eventos en los procesos de pagos que supongan un menor esfuerzo para el cliente.








Ilustración 7. Pago con la cara en un terminal móvil en un minorista.

Las oportunidades provienen de mejorar la experiencia de usuario y de la independencia de las redes tradicionales. El pago en una tienda de comercio electrónico o en un restaurante con un simple gesto de mostrar la cara y sonreír puede ser un buen ejemplo.

Del mismo modo, un grupo de amigos pagará y dividirá fácilmente la factura en un restaurante: uno de ellos tendrá que pagar y, al mismo tiempo, seleccionar la cara de los amigos con los que compartirá la factura. Ellos mostrarán la cara en su móvil y todo el proceso será completado.

El eIDAS y los servicios cualificados de confianza permitirán deshacerse de los terminales punto de venta (TPV) y las tarjetas de crédito. Una aplicación en el lado del comerciante se podrá comunicar de forma universal, segura y *seamless* con la aplicación del cliente. Así, el acto de pagar, en cualquier momento y situación, supondrá solo un

gesto mínimo, en el que las personas mostrarán su cara en el móvil y se identificarán en cuestión de segundos.

#### 4. Del crédito al consumo, al consumo por suscripción

Spotify y Netflix, entre otros, están cambiando la forma de consumir servicios.

Gracias a la tecnología financiera y regulatoria y al estilo de vida digital, también se cambiará la forma de consumir productos. En el eIDAS está la clave de esta transformación, porque la nueva generación de servicios de confianza electrónica permitirá generar un ecosistema de seguridad y el lanzamiento de nuevos servicios, cumpliendo con la regulación y en un entorno de confianza y experiencia inigualable para los clientes.

Ya conocemos ejemplos: el *renting* o *leasing* de los coches o la financiación de terminales por parte de las operadoras son algunos. Sin embargo, la expe-

riencia del cliente aún depende mucho del canal presencial y de una cadena de suministro óptima.

Vamos a vivir un momento donde la financiación del consumo se moverá al consumo por suscripción de bienes. El concepto se convertirá en uso común, gracias a la nueva regulación y, sobre todo, a la tecnología regulatoria. Conectar el espacio físico del minorista (véase una tienda de coches, un espacio de tecnología, electrodomésticos, textil, mobiliario...) y llevarlo a una experiencia multicanal y con una cadena de suministros optimizada es posible.

El concepto de inversión se cambiará por el concepto de suscripción con el estilo de vida digital.

#### 5. Las monedas virtuales

«En los próximos meses, las monedas virtuales van a pasar de ser un activo especulativo a *mainstream*».

La Comisión Europea ha lanzado la nueva directiva AML5, que está en vigor desde el 9 de julio de 2018. Uno de sus principales objetivos es dar entrada a la moneda virtual y que pueda ser tratada específicamente en relación con la prevención del blanqueo de capitales y la financiación del terrorismo.

La desmaterialización de la moneda papel, junto con la homogeneización de los servicios de confianza con el eIDAS, aportarán múltiples beneficios en la dinamización de la economía y negocios transfronterizos en Europa.

Europa vuelve a ser pionera en la adopción de medidas para

la construcción de esta nueva economía. La nueva regulación es la semilla de un futuro criptoeuro o intercambio de otras monedas virtuales en un contexto social de seguridad. Este hecho proporcionará los medios e infraestructura necesarios para facilitar la adopción trasfronteriza de otros conceptos, como el mercado único de pagos y la evolución del crédito al consumo.

## 6. El riesgo: del análisis probabilístico

Gracias a la nueva regulación, el análisis de riesgo de los clientes cambia de un modelo probabilístico a determinístico.

Dadas las restricciones impuestas por la privacidad, el derecho civil garantista europeo no permite el acceso a información de clientes que podría ser potencialmente pública. Esto difiere en los países anglosajones, donde la información pública sí puede ser utilizada.

Este hecho había complicado, hasta la fecha, el acceso a información de riesgo crediticio en relación con los clientes, tanto por la limitación de acceso a la información como por la complejidad para acceder a esa

información en tiempo real. Con el tiempo, la evolución de los *bureaus* de crédito o la gestión interna de las entidades financieras ha mejorado la información, aunque esta sigue siendo vaga y el cálculo es aún probabilístico. Esto hace que la entidad financiera asuma potencialmente más riesgos y, por otro lado, desestime contrataciones o incluso nuevos modelos de negocio por falta de certidumbre en el pago.

El eIDAS permite cambiar este concepto para siempre y cumplir con la ley más exigente en privacidad hasta la fecha, el GDPR. Gracias a la nueva generación de servicios de confianza y a la inteligencia artificial, la industria financiera podrá acceder a la información que las administraciones públicas tienen de las personas (fiscal, trabajo, impagos, demandas, etc.) y hacer uso de ella en tiempo real, en el momento de la contratación.

## 7. Retirada de efectivo en un cajero con una sonrisa

Ya es posible, gracias a la tecnología de identificación electrónica, la retirada de efectivo sin disponer de una tarjeta física, a través de la cara del cliente.

## 8. Optimización de la experiencia del cliente en una oficina

Los campos de aplicación son ilimitados y podemos ver cómo utilizar la tecnología biométrica para conocer al cliente cuando llega a la oficina y optimizar y mejorar su experiencia en las oficinas comerciales.



## VI. CONCLUSIONES

La gestión de la identidad electrónica es clave para entender los servicios financieros y bancarios del futuro. Está cambiando la forma en la que nos podemos relacionar con los clientes en un contexto global y multicanal, pudiendo hacer más convenientes las iteraciones para contratar nuevos productos y servicios.

Las nuevas tecnologías de identidad electrónica: identificación remota de clientes, autenticación biométrica y nuevas firmas electrónicas son *game changers* para generar nuevas ventas y para poner al cliente en el corazón de nuestro negocio. Entender en qué consisten y tenerlas en cuenta en nuestras estrategias de *marketing* y ventas será esencial para la supervivencia de nuestro negocio.

La nueva regulación europea impulsa el uso de las nuevas tec-



nologías, creando un mercado único digital (MUD) que da acceso a 508 millones de consumidores ya que estandariza las cuestiones de la identidad, clave para el negocio transfronterizo. La identidad electrónica y el MUD tendrán un impacto similar al que el euro tuvo a la moneda en Europa a principios de este siglo. Entender y adelantarse a estas circunstancias es importante de cara a aprovechar las nuevas oportunidades que se plantean.

La nueva regulación de prevención de blanqueo de capitales, de privacidad, de pagos y banca abierta o de servicios electrónicos de confianza afianzan la apuesta de Europa por el impulso del sector. Con su entrada en vigor, las oportunidades no solo se plantean para la región, sino que además esta regulación está siendo ampliamente copiada también en otras regiones del mundo y de una forma rápida.

La captación ubicua de clientes, los pagos con la cara, el cambio de la gestión del riesgo a un modelo más determinístico, el consumo por suscripción, cómo las monedas virtuales se convertirán en uso común, la retirada de dinero de un cajero con

una sonrisa o la optimización de oficinas comerciales son solo algunos ejemplos de cómo las nuevas tecnologías de identificación electrónica están impactando en el sector financiero.

#### NOTAS

(1) THE FORRESTER BANKING WAVE™: *European Mobile Apps*, Q2 2019.

(2) A.T. Kearney *Retail Banking Radar* 2019.

#### BIBLIOGRAFÍA

BAFIN (2014). Circular 3/2017.

CAPGEMINI AND BNP PARIBAS (2018). *World Payments Report 2018*.

COMISIÓN EUROPEA (2014). Reglamento (UE) n.º 910/2014 del Parlamento Europeo y del Consejo de 23 de julio de 2014 relativo a la identificación electrónica y los servicios de confianza para las transacciones electrónicas en el mercado interior y por la que se deroga la Directiva 1999/93/CE (Regulación eIDAS).

— (2015). Directiva (UE) 2015/2366 del Parlamento Europeo y del Consejo de 25 de noviembre de 2015 sobre servicios de pago en el mercado interior y por la que se modifican las Directivas 2002/65/CE, 2009/110/CE y 2013/36/UE y el Reglamento (UE) no 1093/2010 y se deroga la Directiva 2007/64/CE.

— (2016). Reglamento (UE) 2016/679 del Parlamento Europeo y del Consejo, de 27 de abril de 2016, relativo a la protección de las personas físicas en lo que respecta al tratamiento de datos personales y a la libre circulación de estos datos y por el que se deroga la Directiva 95/46/CE (Reglamento general de protección de datos) (GDPR).

— (2018). Directiva (UE) 2018/843 del Parlamento Europeo y del Consejo de 30 de mayo de 2018 por la que se modifica la Directiva (UE) 2015/849 relativa a la prevención de la utilización del sistema financiero para el blanqueo de capitales o la financiación del terrorismo, y por la que se modifican las Directivas 2009/138/CE y 2013/36/UE (PSD2).

THE FORRESTER BANKING WAVE™ (2019): *European Mobile Apps*. Forrester Report Q2 2019.

A. T. KEARNEY (2019). *A.T. Kearney Retail Banking Radar Report*.

KPMG (2019). *Global Banking Fraud Survey*. May

NABALÓN, I. (2019). *Electronic Identification –Legal Compliance References–*. April.

SEPBLAC (2016). *Procedimiento de videoidentificación*.

COLABORADORES  
EN ESTE NÚMERO

**ALONSO, Igor.** Es licenciado en Ciencias Actariales y Financieras por la Universidad del País Vasco, Máster en Dirección Aseguradora por la asociación ICEA y Máster en Gestión de Cartera por el Instituto de Estudios Bursátiles. Su carrera profesional la ha desarrollado en consultoras y entidades de inversión internacionales. Actualmente es consejero delegado de Accurate Quant Agencia de Valores S.A., y es especialista en *trading* algorítmico, materia de la que es docente en diferentes escuelas de negocios, articulista y ponente habitual.

**CANO MARTÍNEZ, David.** Licenciado en Dirección y Administración de Empresas por la Universidad Autónoma de Madrid (UAM) y Máster en Finanzas Cuantitativas por Afi Escuela de Finanzas, es socio de Analistas Financieros Internacionales y director general de Afi Inversiones Globales, SGIC, empresa especializada en la gestión de patrimonios, instituciones de inversión colectiva y fondos de pensiones. Más de veinte años de experiencia profesional. Es coautor de una docena de libros de mercados financieros y economía y de más de setenta artículos sobre política monetaria, mercados financieros, fondos de inversión, gestión de carteras y finanzas empresariales. Es profesor de los más prestigiosos centros de posgrado en finanzas españolas (como Afi Escuela de Finanzas Aplicadas) y colabora habitualmente en los medios de comunicación.

**CARBÓ VALVERDE, Santiago.** Nacido en Gandía (Valencia) en 1966. Licenciado en Ciencias Económicas por la Universidad de Valencia, doctor (PhD) in Economics y Máster in Banking and Finance por la University of Wales, Bangor, (Reino Unido). Es catedrático de Economía y Finanzas de CUNEF y de la Bangor University (Reino Unido). Es director de Estudios Financieros de la Fundación Funcas, donde es también director ejecutivo del Observatorio de la Digitalización Financiera. Es profesor investigador del Instituto Valenciano de Investigaciones Económicas (IVIE). Ha sido catedrático de Fundamentos del Análisis Económico de la Universidad de Granada. Es consejero independiente de Cecabank y presidente de su Comisión de Auditoría. Fue presidente de la International Banking, Economics and Finance Association (IBEFA) en 2017. Ha sido miembro del Group of Economic Advisors de la ESMA (European Securities and Market Authority) hasta diciembre de 2018. Es miembro del Consejo Académico del European Banking Institute. Ha sido y aún es, en algunos casos, asesor y colaborador de instituciones públicas como el Banco Central Europeo y la Federal Reserve Bank of Chicago así como también entidades financieras y en consultoras de prestigio internacionales. Autor de más de 200 artículos y publicaciones sobre el sistema financiero. Ha publicado, entre otras, en las siguientes revistas: *Review of Economics and Statistics*, *European Economic Review*, *Review of Finance*, *Journal of Corporate Finance*, *Journal of Money, Credit and Banking*, *Journal of International Money and Finance*, *Journal of Banking and Finance*, *Journal of Financial Services Research*, *Journal of Real Estate Finance and Economics*, *Regional Studies*, *Journal of Economics and Business*, *European Urban and Regional Studies*, *The Manchester School*, *Journal of Productivity Analysis*, *Review of Network Economics*, *Annals of Regional Science*, *Applied Economics*, *European Financial Management*,

*Public Money and Management*, *Spanish Economic Review*, *Journal of International Financial Markets, Institutions and Money*, *Applied Financial Economics*, *Investigaciones Económicas*, *Papeles de Economía Española*, *Perspectivas del Sistema Financiero*, *Revista de Economía Aplicada*, *Hacienda Pública Española-Revista de Economía Pública y Revue de la Banque*. Ha impartido conferencias y seminarios en foros internacionales (G-20, Banco Mundial, World Savings Banks Institute), en varios bancos centrales e instituciones regulatorias (Banco Central Europeo, Federal Reserve Board, Banco de España, Comisión Nacional de la Competencia), en distintos bancos de la Reserva Federal de Estados Unidos, así como en varias universidades, donde también ha sido profesor visitante, entre las que destacan la New York University, Indiana University, Boston College, Florida State University, University of Alberta (Canadá), K.U. Leuven (Bélgica) y University of Warwick (Reino Unido). Es, por último, colaborador frecuente de medios de comunicación escritos, siendo en este momento columnista semanal de *El País* y opinando en otros medios (*Cinco Días*, *El Mundo*, *ABC*, entre otros) y audiovisuales (TVE, La Sexta, Cadena SER, COPE, Radio Nacional de España, etc) en España así como extranjeros (*Financial Times*, *BBC*, *Business Week*, *International Herald Tribune*, entre otros).

**CARRIO, Adrián.** Es ingeniero industrial por la Universidad de Oviedo. Actualmente trabaja como investigador asociado en el Centro de Automática y Robótica de la Universidad Politécnica de Madrid, en el que realiza estudios de doctorado. Ha trabajado además como investigador asociado en el Aerospace Controls Laboratory del Massachusetts Institute of Technology (MIT). Sus intereses como investigador se centran en sistemas de evasión de obstáculos basados en visión artificial para vehículos aéreos no tripulados y el reconocimiento de patrones mediante aprendizaje automático. Es autor de treinta artículos científicos en revistas y congresos internacionales y de una patente.

**CUADROS SOLAS, Pedro Jesús.** Doctor (*cum laude*) en Ciencias Económicas y Empresariales por la Universidad de Granada. Es profesor ayudante doctor en CUNEF e investigador colaborador del Observatorio de la Digitalización Financiera (ODF) de Funcas. Su investigación se centra en el *underwriting*, la reputación bancaria y la digitalización financiera. Sus trabajos de investigación han sido publicados en el *Journal of Corporate Finance* y en libros editados por Springer-Palgrave. Ha presentado en Congresos Internacionales como FMA, WEAL, EFMA y también en Banco de la Reserva Federal de Atlanta y de Filadelfia. En Octubre de 2017, recibió el Premio *ex aequo* a la mejor tesis en Economía por la Real Academia de Doctores de España (RADE). Su artículo, *The impact of lending relationships on the choice and structure of bond underwriting syndicates*, ha recibido el premio *accésit* de investigación de la Fundación de Estudios Financieros (FEF) (Diciembre-2017).

**FERNÁNDEZ BEDOYA, Ana.** Responsable de la Unidad de Nuevos Productos y Servicios, de la División de Innovación Financiera del Banco de España. Esta división fue creada en marzo de 2018 con el objetivo de hacer seguimiento del proceso de innovación financiera y evaluar sus implicaciones potenciales. Junto con su equipo, Ana se dedica a analizar la emergencia de nuevas tendencias y el uso de las nuevas tecnologías, tales como la inteligencia artificial o los registros distribuidos. Con anterioridad a este puesto, Ana trabajó durante quince años en el Departamento de Sistemas de Pago del Banco de España, en cuestiones relacionadas con la evolución del mercado de pagos europeo y con la vigilancia de las infraestructuras del mercado financiero. Es licenciada en Administración y Dirección de Empresas por la Universidad Autónoma de Madrid y tiene un Máster en Negocio Bancario y Agente Financiero por la Universidad de Alcalá de Henares.



**GALEANO, Pedro.** Es doctor en Ingeniería Matemática por la Universidad Carlos III de Madrid y licenciado en Ciencias Matemáticas por la Universidad Autónoma de Madrid. Actualmente es profesor titular del Departamento de Estadística de la Universidad Carlos III de Madrid. Anteriormente fue investigador Posdoctoral de la Universidad de Santiago de Compostela y *Visiting Assistant Professor* de la Universidad de Chicago. Ha publicado más de treinta artículos de investigación en Estadística y Econometría. Es editor asociado del *Journal of Time Series Analysis* y de *Heliyon*.

**GORJÓN RIVAS, Sergio.** Es el responsable de la Unidad de Nuevos Proveedores y Regulación. Previamente ha ocupado distintos cargos en el Departamento de Sistemas de Pago, incluyendo la Jefatura de la División de Políticas Públicas y Vigilancia desde donde ha contribuido al diseño de políticas públicas de fomento de la innovación en el ámbito de las infraestructuras del mercado financiero y de los pagos minoristas. Ha trabajado, igualmente, para el Banco Mundial como Especialista del Sector Financiero. En la actualidad forma parte de diversos grupos de trabajo a escala internacional cuya misión es la evaluación del impacto de la transformación digital sobre la estructura y el funcionamiento de la industria financiera así como el fomento de la adopción de nuevas herramientas tecnológicas para el mejor desempeño de las tareas regulatorias y supervisoras. Es licenciado en Ciencias Económicas y Empresariales por el CUNEF y tiene un Máster en Dirección de Entidades Financieras por el IEB.

**HASAN, Iftekhar.** Es profesor de la Fordham University, donde ocupa la cátedra E. Gerald Corrigan Chair in Finance en la Gabelli School of Business. Es también asesor científico del Banco de Finlandia y managing editor del *Journal of Financial Stability*. Sus intereses de investigación se centran en las entidades financieras, las finanzas corporativas, los mercados de capitales y las economías emergentes. Cuenta con más de 350 publicaciones que incluyen dieciséis libros y volúmenes editados y más de 275 artículos en revistas científicas en finanzas, economía, negocios internacionales, gestión, contabilidad, investigación operativa y sistemas de información. Fue becario Fulbright y ahora está en el comité de selección Fulbright. También ha recibido el prestigioso premio «Changjiang Scholar» del Ministerio de Educación de China y el premio «Shimomura Fellow» del Development Bank of Japan. Es doctor *honoris causa* por la Romanian-American University de Bucharest.

**HE, Qing.** Es profesor de finanzas en la School of Finance de la Renmin University. También es editor en jefe de *Economic and Political Studies*. Sus intereses de investigación se centran en desarrollo financiero, políticas financieras y finanzas internacionales. Ha publicado en numerosas y prestigiosas revistas como *Review of Finance*, *Financial Management*, *Journal of Comparative Economics*, etc. Su trabajo de investigación ha sido presentado en múltiples reuniones científicas internacionales y ha tenido impacto en muchos medios públicos.

**LOZANO, Jesús.** Fue economista sénior en el área de Regulación Digital y Tendencias de BBVA Research. Desde enero de 2019 se incorporó a Regulación y Control Interno en la unidad de Regulación. En 2001 se incorporó a BBVA, donde ha desempeñado diversas funciones relacionadas con las operaciones de extranjero, los servicios de compensación, la transformación operativa y el impacto de las regulaciones en sistemas. Desde 2008 su actividad ha estado muy vinculada a la implementación del Área Única de Pagos en Euro (SEPA), participando en proyectos internos y grupos interbancarios, como el grupo europeo que desarrolló en 2016 el estándar de Pagos Instantáneos en Euro. Actualmente centra su actividad en el análisis de tendencias y aspectos regulatorios en las áreas de pagos, inteligencia artificial, *cloud computing* y ciberseguridad.

Jesús es licenciado en Economía, especialidad de Análisis Económico por la Universidad de Zaragoza, posee un Máster en Data Management e Innovación Tecnológica por la OBS Business School y completó un Curso Experto Universitario en Data Science Practitioner en la Universidad Internacional de La Rioja.

**LU, Haitian.** Es vicedeano de la Facultad de Negocios y catedrático de la School of Accounting and Finance de la Hong Kong Polytechnic University. Es también subdirector del Center for Economic Sustainability and Entrepreneurial Finance (CESEF) de la misma universidad. Sus trabajos de investigación han sido publicados en revistas de derecho, finanzas, economía y gestión. Su trabajo de investigación ha sido presentado en múltiples reuniones científicas internacionales y ha tenido impacto en muchos medios públicos.

**MARQUÉS SEVILLANO, José Manuel.** Jefe de la División de Innovación Financiera en el Banco de España. Sus principales responsabilidades incluyen analizar los principales cambios en el sistema financiero y sus implicaciones para las autoridades económicas y financieras. Se incorporó al Banco de España en 1996 y ha ocupado distintos puestos en el Servicio de Estudios y en Asuntos Internacionales incluyendo la responsabilidad de la División de Mercados Financieros Internacionales. Ha escrito varios artículos sobre mercados financieros, estabilidad financiera, análisis macro-financiero o valoración de activos y ha participado, desde su fundación en la representación española en el Grupo de estudio del G20 sobre finanzas sostenibles. Es licenciado en Ciencias Económicas y Empresariales por la Universidad de Zaragoza y tiene un MsC en Economía por la Universidad Pompeu Fabra.

**NABALÓN, Iván.** Es uno de los principales «influenciadores» en identidad digital en Europa, entre los cien del mundo nombrados por OWI (*One World Identity*), la principal patronal del sector. Esto es debido a su trabajo como emprendedor y líder de pensamiento en relación con la identificación electrónica en los últimos diez años. Iván es fundador de Civitana.org, la mayor red social en el mundo donde la participación ciudadana es legalmente vinculante. También es además, fundador y CEO de Electronic Identification, el fabricante de *software* líder mundial en sistemas de identificación electrónica en el sector financiero.

**PEÑA, Daniel.** Es profesor emérito de la Universidad Carlos III de Madrid. Ha sido catedrático de Estadística en las universidades Politécnica de Madrid, University of Chicago y Carlos III de Madrid, donde ha sido rector entre 2007 y 2015 y creador del Instituto de Big Data UC3M-Banco de Santander en 2015. Ha escrito catorce libros, publicado más de 220 artículos de investigación y recibido premios científicos como el Jack Youden Prize en EE.UU. y el Premio Rey Jaime I de Investigación en Economía en España. Es miembro de la Real Academia de Ciencias y *Fellow* (miembro de honor) de The American Statistical Association y The Institute of Mathematical Statistics.

**PEÓN, David.** Profesor docente e investigador a tiempo completo en el Departamento de Empresa de la Universidade da Coruña (UDC). Actualmente es coordinador del Máster Universitario en Banca y Finanzas de la UDC, único Máster en España acreditado por CNMV y Banco de España. Sus líneas de investigación incluyen, entre otras, las finanzas del comportamiento y el emprendimiento en áreas rurales. Cuenta con una veintena de publicaciones en revistas indexadas en *JCR* y *Scopus*. Cuenta asimismo con más de diez años de experiencia profesional en Gestión de Activos y Banca Privada (Grupo BBVA).

**PÉREZ SÁNCHEZ, Jesús.** Crypto economista, fundador del Digital Assets Institute y director de Crypto Plaza. Fundador de Fintech



Ventures y Civeta Investment. Gestor de Crypto Funds Tokenomics Stars en Iconomi. Fundador de Sersan Sistemas y AccurateQuant. Profesor del Instituto de Estudios Bursátiles (IEB). Miembro del Instituto Español de Analistas Financieros. Ingeniero informático de la Universidad Autónoma de Madrid. Fundador de Agile-Spain.

**RODRIGO, Tomasa.** Es actualmente responsable de proyectos Big Data en BBVA Research relacionados con el análisis económico, social y geopolítico. Tiene una gran experiencia trabajando con infraestructuras en la nube, grandes masas de datos de índole financiera y social (medios de comunicación y redes sociales). Ha publicado varios artículos sobre el seguimiento de eventos geopolíticos, sociales y económicos con Big Data y ha sido mencionada en sonados blogs como O'Reilly y Forbes. Es licenciada en Economía por la Universidad de Granada (Summa Cum Laude) donde trabajó de ayudante de investigación dos años. Realizó un Máster en Análisis Económico en la Universidad Carlos III de Madrid (Nota de la tesis: 10/10) y ejerció como docente de Econometría durante un año. También realizó un Máster en Big Data impartido por IBM. Además, ha publicado en revistas académicas como *Eurasian Journal of Social Science* y ha colaborado en periódicos y revistas como *El País* y presentado en importantes foros de debate en el área de la ciencia de datos como bancos centrales, Big Data Spain, Machine Learning Spain y Google Cloud Summit.

**RODRÍGUEZ FERNÁNDEZ, Francisco.** Nacido en Granada en 1975. Doctor en Ciencias Económicas y Empresariales por la Universidad de Granada. Catedrático de Fundamentos del Análisis Económico de la Universidad de Granada. Ha realizado estudios de posgrado en las universidades de Módena y Boloña (Italia). Es economista sénior en la Fundación Funcas y coordinador del Observatorio de la Digitalización Financiera. Ha sido y aún es, en algunos casos, asesor y consultor de instituciones públicas como el Banco Central Europeo y consultoras de prestigio internacionales. Investigador visitante en la New York University, Bangor University y el Banco de la Reserva Federal de Chicago. Autor de más de cien artículos y publicaciones sobre el sistema financiero. Ha publicado, entre otras, en las siguientes revistas: *The Review of Economics and Statistics*, *European Economic Review*, *Journal of Corporate Finance*, *Review of Finance*, *Journal of Money, Credit and Banking*, *Journal of Financial Stability*, *Journal of International Money and Finance*, *Journal of Banking and Finance* o *Journal of Financial Services Research*. Colaborador de *Expansión* y *Cinco Días*.

**SICILIA, Jorge.** Es economista Jefe del Grupo BBVA y director de BBVA Research. Dirige un equipo global de economistas repartido entre Europa, EE.UU., Hong Kong, Turquía, México y América del Sur dedicado al análisis económico y financiero. Es miembro del COAP de BBVA. Anteriormente, fue economista jefe de Norte América supervisando a los equipos de análisis económicos en EE.UU. y México, fue Economista principal en la División de Política Monetaria en el Banco Central Europeo (BCE) en Frankfurt, economista jefe de Mercados Monetarios y Financieros en BBVA en Madrid, director del Departamento de Estudios Económicos y Monetarios en Argentina, director de Análisis Económicos y de Mercados en Analistas Financieros Internacionales (AFI) y economista en el Departamento de Estudios Económicos del Tribunal de Defensa de la Competencia. Ha sido profesor de macroeconomía, mercados financieros y sistemas financieros en CUNEF y en la Universidad Carlos III de Madrid, además de impartir clase en instituciones de postgrado, y participar como ponente en conferencias académicas y bancos centrales. Obtuvo la Licenciatura en Economía por la Universidad Complutense de Madrid en 1992, y tiene un Máster en Economía y Finanzas por el Centro de Estudios Monetarios y Financieros (CEMFI) en 1994. Es autor de varias publicaciones en revistas especializadas, miembro de la Fundación BBVA Bancomer, de la Fundación de Estudios Financieros del ITAM y del Comité de Inversores y Acreedores Privados de Grecia (PCIC).

**Vives, Xavier.** Es profesor de Economía y Finanzas de IESE Business School. Es doctor en Economía por la Universidad de California, Berkeley. Ha sido profesor en INSEAD (París) en 2001-2005; Director del Instituto de Análisis Económico del CSIC en la década 1991-2001; profesor en Harvard University, Universitat Autònoma de Barcelona, Universitat Pompeu Fabra, the University of California at Berkeley, the University of Pennsylvania, and New York University. Sus campos de interés son economía industrial y su regulación, banca y economía financiera. Ha publicado más de ciento treinta artículos de investigación y es autor de diversos libros. Entre los premios recibidos: Rey Don Juan Carlos I de Investigación en Ciencias Sociales, 1988; European Research Council Advanced Grant en 2008 y en 2017, y el Rey Jaime I de Economía en 2013. Es miembro de la Academia Europea desde 2012. Duisenberg *Fellow* del Banco Central Europeo en 2015.



## PUBLICACIONES DE FUNCAS

### Últimos números publicados:

#### PAPELES DE ECONOMÍA ESPAÑOLA

N.º 160. Medicamentos, innovación tecnológica y economía

N.º 161. Presente y futuro de la Seguridad Social

#### PANORAMA SOCIAL

N.º 29. Pobreza y rentas mínimas

N.º 30. Opinión pública y encuestas

#### CUADERNOS DE INFORMACIÓN ECONÓMICA

N.º 273. Desaceleración económica y mercado de la vivienda

#### SPANISH ECONOMIC AND FINANCIAL OUTLOOK

Vol. 8, N.º 6 (2019) Spain: Assessing real estate and credit markets ahead of an anticipated slowdown

#### PAPELES DE ENERGÍA

N.º 8. Enero (2020)

#### ESTUDIOS DE LA FUNDACIÓN

N.º 91. Crisis económica y desigualdad de la renta en España. Efectos distributivos de las políticas públicas

#### LIBROS

El sector público español: reformas pendientes

## AÑO 2020

| Publicación                            | Suscripción*      |                    |                 | Números sueltos**  |                 |
|----------------------------------------|-------------------|--------------------|-----------------|--------------------|-----------------|
|                                        | Suscripción anual | Edición papel<br>€ | Edición digital | Edición papel<br>€ | Edición digital |
| Papeles de Economía Española           | 4 números         | 55                 | Gratuita        | 20                 | Gratuito        |
| Cuadernos de Información Económica     | 6 números         | 45                 | Gratuita        | 15                 | Gratuito        |
| Panorama Social                        | 2 números         | 25                 | Gratuita        | 18                 | Gratuito        |
| Spanish Economic and Financial Outlook | 6 números         | 35                 | Gratuita        | 15                 | Gratuito        |
| Papeles de Energía                     | 2 números         | 25                 | Gratuita        | 18                 | Gratuito        |
| Estudios (números sueltos)             | --                | --                 | Gratuita        | 17                 | Gratuito        |

Los precios incluyen el IVA. No incluyen los gastos de envío.

\* Gastos de envío: España, 7€/año; Europa, 10€/ejemplar; resto países: 20,85€/ejemplar.

\*\* Gastos de envío: correo postal (Madrid y provincias): 1€.

Servicio de mensajería: Madrid capital, 3,45€; resto provincias, 10,44€.

Forma de pago: domiciliación bancaria, transferencia bancaria.

## SUSCRIPCIÓN Y PEDIDOS

INTERNET: <http://www.funcas.es/Publicaciones/Publicaciones.aspx?Id=0>

E-MAIL: [publica@funcas.es](mailto:publica@funcas.es)









# funcas

## PAPELES DE ECONOMÍA ESPAÑOLA

### Últimos números publicados

- nº 140 *La política monetaria tras la Gran Recesión*
- nº 141 *El reto de la unión fiscal europea*
- nº 142 *La triple meta para el futuro de la sanidad*
- nº 143 *La nueva reforma de la financiación autonómica:  
Análisis y propuestas*
- nº 144 *La industria española: Un impulso necesario*
- nº 145 *Regulación y política de defensa de la competencia  
en España*
- nº 146 *Mercados de crédito*
- nº 147 *Gasto público en España: presente y futuro*
- nº 148 *Las comunidades autónomas dispuestas a crecer*
- nº 149 *Transformación digital en los medios de pago*
- nº 150 *Competitividad en los mercados internacionales:  
búsqueda de ventajas*
- nº 151 *Economía y Derecho*
- nº 152 *Redes de interacción social y espacial: aplicaciones  
a la economía española*
- nº 153 *Economía de las ciudades*
- nº 154 *La teoría económica de las reformas fiscales:  
análisis y aplicaciones para España*
- nº 155 *El negocio bancario tras las expansiones cuantitativas*
- nº 156 *Los problemas del mercado de trabajo y las reformas  
pendientes*
- nº 157 *Análisis económico de la revolución digital*
- nº 158 *El sector exterior en la recuperación*
- nº 159 *Deporte y Economía*
- nº 160 *Medicamentos, innovación tecnológica y economía*
- nº. 161 *Presente y futuro de la Seguridad Social*

