

BIG DATA

ANÁLISIS FINANCIERO Y BIG DATA

Santiago Carbó
Juan José Ganuza
Daniel Peña
Pilar Poncela
(editores)

BIG DATA

ANÁLISIS FINANCIERO Y BIG DATA

Santiago Carbó
Juan José Ganuza
Daniel Peña
Pilar Poncela
(editores)



Funcas

PATRONATO

ISIDRO FAINÉ CASAS
JOSÉ MARÍA MÉNDEZ ÁLVAREZ-CEDRÓN
FERNANDO CONLLEDO LANTERO
ANTÓN JOSEBA ARRIOLA BONETA
MANUEL AZUAGA MORENO
CARLOS EGEA KRAUEL
MIGUEL ÁNGEL ESCOTET ÁLVAREZ
AMADO FRANCO LAHOZ
PEDRO ANTONIO MERINO GARCÍA
ANTONIO PULIDO GUTIÉRREZ
VICTORIO VALLE SÁNCHEZ

DIRECTOR GENERAL

CARLOS OCAÑA PÉREZ DE TUDELA

Impreso en España
Edita: Funcas
Caballero de Gracia, 28, 28013 - Madrid
© 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.

ISBN: 978-84-17609-67-2
Depósito legal: M-14517-2023
Maquetación: Funcas
Imprime: Cecabank



Contenido

Presentación <i>Santiago Carbó, Juan José Ganuza, Daniel Peña y Pilar Poncela</i>	1
Capítulo I. Digitalización financiera pospandemia: una aproximación basada en aprendizaje automático <i>Santiago Carbó-Valverde, Pedro J. Cuadros-Solas y Francisco Rodríguez-Fernández</i>	5
Capítulo II. Negociación de alta frecuencia y calidad del mercado: revisión de una década de investigación <i>Roberto Pascual</i>	29
Capítulo III. Aprendizaje automático en modelos de concesión de crédito: oportunidades y riesgos <i>Andres Alonso-Robisco y Jose Manuel Carbo</i>	79
Capítulo IV. ¿Es posible batir a los mercados financieros usando herramientas de <i>big data</i> y de <i>machine learning</i> ? <i>Francisco J. Nogales</i>	105
Capítulo V. Aprendizaje profundo para series temporales en finanzas: aplicación al factor <i>momentum</i> <i>Iván Blanco, Sergio J. García y Álvaro Remesal</i>	123
Capítulo VI. Aprendizaje automático aplicado a la compraventa de criptomonedas <i>Gian Pietro Enzo Bellocca</i>	149
Capítulo VII. Transacciones financieras y economía en tiempo real y alta definición: el consumo español <i>Alvaro Ortiz Vidal-Abarca y Tomasa Rodrigo</i>	175
Capítulo VIII. ¿Sueña la inteligencia artificial con cárteles virtuales? <i>Jose Penalva</i>	205
Capítulo IX. Diferencias de género en la investigación económica. Un enfoque de aprendizaje automático <i>J. Ignacio Conde-Ruiz, Juan-José Ganuza, Manu García y Luis A. Puch</i>	227

Presentación

La disponibilidad de datos masivos, el llamado *big data*, y de métodos de cálculo y procesamiento cada vez más potentes está afectando profundamente a los sistemas financieros en todo el mundo. Por ejemplo, la negociación de acciones ya no se realiza en los antiguos edificios de las bolsas, construidos en los centros financieros de las grandes ciudades en el siglo XIX, el de Madrid data de 1831. Las amplias salas, los parques, donde se realizaba la compra y venta de las acciones por los agentes de bolsa, están siendo sustituidos por conjuntos de ordenadores que, con métodos de inteligencia artificial, negocian automáticamente las operaciones bursátiles. Las monedas ya no son exclusivamente controladas por los bancos centrales y han aparecido las criptomonedas, que se escapan del control de las herramientas financieras tradicionales. Las mayores empresas del mundo ya no son las propietarias de grandes activos físicos donde trabajan miles de empleados, sino aquellas basadas en utilizar los datos para crear productos de alta tecnología y plataformas informáticas que conectan a los clientes con los proveedores de servicios.

Este libro presenta nueve trabajos sobre distintos aspectos de los cambios que están transformando el mundo financiero como consecuencia de la revolución en el procesamiento y la disponibilidad de grandes masas de datos. Estos trabajos fueron presentados en las jornadas sobre “Análisis financiero y Big Data” celebradas en Funcas el 26 de octubre de 2022, organizadas por los editores de este libro. El lector interesado puede consultar las presentaciones realizadas en el canal de Funcas en Youtube. Esta monografía se añade a las tres ya publicadas en esta colección de Funcas sobre el efecto del *big data* en determinados aspectos de la actividad económica. Las anteriores se centraron en los métodos de predicción, los procedimientos de análisis económico cuantitativo o econométrico y el *marketing* digital.

El primer trabajo incluido en este volumen aborda el problema de la identificación de variables para prever la digitalización de las entidades financieras, y ha sido realizado por **Santiago Carbó-Valverde, Pedro J. Cuadros-Solas, y Francisco Rodríguez-Fernández**. Esta investigación analiza una encuesta realizada a usuarios *online* de entidades bancarias y concluye que los principales factores que predicen el grado de digitalización financiera son la utilidad percibida de los consumidores sobre la banca digital para consultar saldos, transferir dinero y relacionarse con el banco.

En el capítulo II, **Roberto Pascual** evalúa cómo los cambios en los datos disponibles y en la computación facilitan la rápida comunicación entre máquinas ofreciendo oportunidades

de beneficio de duración muy corta, inferiores al segundo, lo que se conoce como negociación de alta frecuencia o *high frequency trading* (HFT). Se concluye que el efecto neto del HFT ha sido positivo, aunque puede tener externalidades negativas tanto sobre los proveedores de liquidez como sobre la negociación informada.

La concesión de créditos mediante algoritmos de aprendizaje automático se ha extendido por las entidades financieras y **Andrés Alonso-Robisco** y **José Manuel Carbó** analizan las consecuencias de su implantación estudiando distintas técnicas de interpretabilidad de los algoritmos tipo “caja negra” frecuentemente utilizados. Concluyen en la necesidad de avanzar en la interpretación de estos métodos automáticos para lograr una satisfactoria explicación de los mismos, como condición necesaria para dar confianza a los usuarios y a los reguladores del buen funcionamiento de estos sistemas automatizados de concesión.

El análisis de los mercados de valores desde la nueva perspectiva de datos masivos se analiza en los capítulos IV y V. En el capítulo IV, **Javier Nogales** presenta una panorámica de los modelos utilizados para prever el mercado de valores y cómo la aparición de los métodos automáticos basados en la rapidez de computación y los datos masivos suponen un cambio de paradigma en el funcionamiento de dicho mercado. En particular, los modelos de *machine learning* y de aprendizaje estadístico están permitiendo obtener rendimientos superiores al mercado de forma consistente aprovechando las no linealidades y los efectos inmediatos que pueden captarse con las tecnologías actuales. Este trabajo se complementa con el capítulo V escrito por **Iván Blanco**, **Sergio J. García** y **Álvaro Remesal**. En él, los autores presentan un interesante ejemplo, con datos del mercado de EE. UU., de cómo aprovechar el efecto *momentum* o inercia frecuente en los valores cotizados para mejorar su predictibilidad utilizando las redes neuronales profundas recurrentes con efectos dinámicos. Ambos trabajos ilustran de forma muy clara la revolución que se está desarrollando actualmente en el funcionamiento del mercado de valores.

Los nuevos sistemas de divisas, las criptomonedas, se analizan en el capítulo VI de **Gian Pietro Enzo Belloca**, que está relacionado con los dos anteriores al considerar también el *momentum* o efecto de inercia en la evolución de un activo para la predicción del precio de una criptomoneda. Este trabajo proporciona una visión general de la tecnología *blockchain* y cómo ha llevado al nacimiento de una nueva moneda digital. Posteriormente, se centra en la predicción y explotación del efecto *momentum* en tres de las principales criptomonedas bitcíoín (BTC), ethereum (ETH) y litecoin (LTC), en los dos últimos años. Se comprueba de nuevo que, como en la predicción de los precios de las acciones, los modelos de aprendizaje automático pueden predecir, mediante el análisis de grandes bases de datos, la volatilidad de los precios a corto plazo, aumentando el rendimiento de la inversión en comparación con los enfoques tradicionales.

La posibilidad de explotar la información de las transacciones financieras para mejorar la contabilidad nacional se aborda por **Alvaro Ortiz Vidal-Abarca** y **Tomasa Rodrigo** en el capítulo VII. Los autores ilustran cómo las transacciones financieras de la vida diaria constituyen una rica fuente de información para aproximar el comportamiento de una economía en tiempo real. En concreto, nos permite aproximar las cuentas nacionales tanto

por el lado de la demanda, como por el de la oferta y de la renta a una frecuencia mucho más elevada y con un grado de detalle muy superior al incluido normalmente en las encuestas. Esta propiedad se ilustra con el análisis del consumo español.

José Penalva analiza en el capítulo VIII cómo la inteligencia artificial (IA) se aplica para fijar precios en muchos sectores como préstamos, seguros, billetes de hotel y avión, alquileres, etcétera. En este trabajo se estudia el posible impacto de este uso de la IA, y la necesidad de que las políticas de competencia adapten sus planteamientos a este nuevo contexto.

Finalmente, en el último capítulo, **J. Ignacio Conde-Ruiz, Juan José Ganuza, Manu García y Luis A. Puch** abordan las diferencias de género en la investigación económica desde el aprendizaje automático, utilizando una base de datos de resúmenes de artículos publicados en las mejores revistas de economía para demostrar que existen diferencias significativas en el enfoque y elección de temas en la investigación de hombres y mujeres. El trabajo incluye un estudio específico sobre el análisis de estas diferencias en el campo de finanzas.

Confiamos en que este conjunto de trabajos será de utilidad a una audiencia amplia de lectores que quiera introducirse en los grandes cambios que los datos masivos están produciendo en las estrategias financieras. Agradecemos a todos los autores su esfuerzo y generosidad para difundir su experiencia en beneficio de todos los lectores.

Como editores de este libro queremos agradecer el apoyo de Funcas a esta iniciativa y, especialmente a su director general, Carlos Ocaña, que ha impulsado el área de *big data* dentro de la Fundación. Agradecemos a todo su equipo las facilidades para la realización de las jornadas y a la responsable de publicaciones en Funcas, Myriam González, su eficaz trabajo en la publicación de esta monografía.

Santiago Carbó, Juanjo Ganuza, Daniel Peña y Pilar Poncela

Abril, 2023

CAPÍTULO I

Digitalización financiera pospandemia: una aproximación basada en aprendizaje automático

Santiago Carbó-Valverde
Pedro J. Cuadros-Solas
Francisco Rodríguez-Fernández

Este trabajo examina cuáles son los factores que predicen el grado de digitalización financiera en un contexto pospandémico. Usando una encuesta realizada en España a 2.121 usuarios *online* –entre 18 y 70 años– se emplea el *random forest* y *extreme gradient boosting* para predecir el proceso de digitalización financiera. El estudio muestra que las técnicas de aprendizaje automático predicen con un elevado grado de precisión el grado de digitalización financiera. Los principales predictores son la necesidad/utilidad percibida sobre la banca digital para consultar saldos, transferir dinero y relacionarse con el banco.

Palabras clave: digitalización financiera, aprendizaje automático, banca digital, pospandemia.

1. INTRODUCCIÓN

El uso de técnicas de aprendizaje automático (*machine learning*) en el campo de la banca y de las finanzas puede ayudar a examinar y simplificar la respuesta ante cuestiones que, hasta este momento, eran complejas. El potencial de los algoritmos para revelar patrones en un amplio conjunto de datos hace que el aprendizaje automático comience a ser utilizado dentro del análisis financiero. En concreto, la utilización de algoritmos de *machine learning* puede ser de interés en el campo de la digitalización financiera. Dicho proceso de transformación digital de los consumidores es especialmente complejo, ya que intervienen una combinación amplia de factores –sociales, conductuales, aptitudinales, perceptuales y relaciones– (Carbó-Valverde, Cuadros-Solas y Rodríguez-Fernández, 2020; Lin, Wang y Hung, 2020). En relación a las técnicas econométricas más usadas en la literatura para estudiar fenómenos como el grado de adopción de la banca digital o de determinados medios de pago digitales, el aprendizaje automático ofrece la posibilidad de revelar patrones de comportamiento de los consumidores que, hasta el momento, no eran obvios (Cui, Wong y Lui, 2006; Bajari *et al.*, 2015).

La aplicación de estas técnicas sobre el proceso de digitalización financiera ha ganado relevancia desde la pandemia de COVID-19. Como se ha venido observando desde la irrupción de la pandemia, todo el proceso de transformación digital de las sociedades se ha acelerado significativamente (Fu y Mishra, 2022). La pandemia ha provocado una transición acelerada de las empresas, consumidores y administraciones hacia un mundo más digital y tecnológico. En la mayor parte de las sociedades se evidencia un cambio en la forma en la que los distintos agentes sociales se relacionan o interactúan. Esta digitalización acelerada también ha impregnado sustancialmente a las finanzas. Por una parte, las instituciones financieras han visto la necesidad de intensificar sus planes de transformación tecnológica asumiendo para ello la adopción de nuevas tecnológicas bancarias –*blockchain*, *cloud computing*, biometría, inteligencia artificial o *big data*–. Por lo que respecta a la demanda, los consumidores han experimentado un salto digital en la gestión de sus finanzas. El acceso a servicios financieros *online* se ha popularizado, incluso en segmentos de población que estaban menos digitalizados antes de la pandemia (Carbó-Valverde, Cuadros-Solas y Rodríguez-Fernández, 2021). Además, lejos de ralentizarse una vez superada la fase más dura de la pandemia, parece seguir avanzando. Por ello, desde el punto de vista de la demanda, es importante comprender cómo las personas están respondiendo, a raíz de la pandemia, a dicha transformación tecnológico-financiera resulta más relevante aún. Además, como han puesto en evidencia algunos estudios, la inclusión digital genera una serie de beneficios para los propios clientes. En general, el acceso a servicios financieros digitales permite a los clientes obtener unas mejores condiciones –menos comisiones– y la posibilidad de reducir los costes de transacción para acceder al crédito.

Este capítulo pretende aprovechar las ventajas que ofrecen las técnicas de aprendizaje automático para examinar el grado de digitalización financiera de los consumidores en un contexto pospandémico. En concreto, el presente trabajo pretende avanzar en el conocimiento del proceso de digitalización bancaria de dos formas. En primer lugar, usando las técnicas de *machine learning* para mejorar la fiabilidad de las predicciones sobre el grado de digitalización bancaria de los consumidores. Y en segundo lugar, esclareciendo qué tipos de factores son los que inciden en mayor medida en dicho grado de digitalización.

Para tratar de conseguir los objetivos propuestos, el trabajo examina el proceso de digitalización financiera considerando cuatro dimensiones diferentes de este fenómeno: la adopción de la banca digital, el alcance de uso de la banca digital, la conversión en cliente de un banco exclusivamente digital y la adopción de medios de pagos no bancarios. El examen diferenciado de cada una de estas dimensiones ayuda a dar una respuesta más específica y detallada a las diferentes aristas que plantea el proceso de digitalización financiera. Desde un punto de vista empírico, este trabajo emplea una encuesta sobre el uso de los servicios bancarios digitales, los medios de pago digitales y la adopción de los criptoactivos realizada en diciembre de 2021 por 2.121 individuos de entre 18 a 70 años residentes en España. Sobre la base de dicha encuesta, representativa de la población española adulta, se emplean un conjunto de técnicas de aprendizaje automático. En concreto, el estudio utiliza dos de los algoritmos más populares en el campo del aprendizaje automático supervisado: *random forest* y *extreme gradient boosting*. Ambas técnicas presentan un conjunto de ventajas metodológicas para tratar de responder a la pregunta de investigación.

A modo de resumen, el presente trabajo concluye que las técnicas de aprendizaje automático son capaces de predecir con un elevado grado de precisión el grado de digitalización financiera de los consumidores. Además, muestra que los principales factores que predicen el grado de digitalización financiera son la necesidad/utilidad percibida de los consumidores sobre la banca digital para consultar saldos, transferir dinero y comunicarse con el banco. Sin embargo, los factores sociales –edad, población, nivel de estudios, nivel de ingresos, situación laboral– son los más relevantes para predecir quiénes usan medios de pago no bancarios y quiénes son clientes de bancos 100 % digitales. Estos resultados sugieren que existen diferencias relevantes en cómo se produce el proceso de digitalización financiera dependiendo de si el proveedor de dichos servicios es una entidad financiera tradicional o si se trata de un nuevo proveedor de servicios financieros (neobanco, *fintech* y/o *bigtech*).

El capítulo se estructura en cinco secciones que siguen a esta introducción. En la segunda sección se hace un repaso por el potencial que tiene el aprendizaje automático para examinar el proceso de digitalización financiera. En la sección tercera se describen los datos que van a emplear para examinar la pregunta de investigación. La metodología empleada, con una descripción pormenorizada de las técnicas de *machine learning* usadas, se analiza en la cuarta sección. La quinta sección se centra en presentar los resultados empíricos obtenidos y en discutir las implicaciones de dichos resultados en el entorno pos-COVID. Finalmente, la sexta sección presenta las conclusiones.

2. LA DIGITALIZACIÓN FINANCIERA A TRAVÉS DEL *MACHINE LEARNING*

Numerosos estudios han tratado de examinar cómo se produce el proceso de digitalización de los individuos. Es decir, qué determina que los individuos adopten el canal digital para realizar actividades que anteriormente realizaban de una manera presencial. Si bien, examinar el proceso de digitalización es complicado, ya que existen varios y complejos factores

que impulsan la digitalización de las personas (Pousttchi y Dehnert, 2018). En lo que respecta a la digitalización financiera, varios estudios empíricos han corroborado que dicho proceso es multifactorial (Carbó-Valverde, Cuadros-Solas y Rodríguez-Fernández, 2020; Lin, Wang y Hung, 2020), donde factores socioeconómicos, conductuales, aptitudinales, perceptuales y/o relacionales juegan, todos ellos, un papel relevante.

Desde un punto de vista metodológico, para examinar las preferencias de los consumidores con respecto al uso de los medios digitales para realizar pagos u otros servicios financieros, la mayoría de los estudios anteriores han empleado técnicas econométricas estándares. Entre ellas, han predominado el uso de modelos de elección discreta (Hernández-Murillo, Llobet y Fuentes, 2010; Yusuf Dauda y Lee, 2015) y de ecuaciones estructurales (Aldás-Manzano *et al.*, 2009; Montazemi y Qahri-Saremi, 2015). A pesar de las bondades que presentan estos modelos econométricos, parece que la complejidad que caracteriza el proceso de digitalización financiera puede requerir del uso de otras técnicas que permitan ser capaces de aprovechar el uso de cantidades ingentes de datos para poder revelar patrones ocultos en el comportamiento digital de los individuos.

En este sentido, los métodos de aprendizaje automático se revelan como herramientas poderosas para aportar luz acerca del comportamiento de los consumidores (Cui, Wong y Lui, 2006; Witten, Frank y Hall, 2019; Lecun, Bengio y Hinton, 2015). La utilización de algoritmos de aprendizaje automático permitiría revelar los patrones complejos que impulsan el proceso de digitalización, ya que estos algoritmos pueden identificar patrones o conocimientos complejos y no obvios. El uso de estas técnicas puede ayudar a los modelos econométricos a revelar aquellos patrones de comportamiento que pueden estar más ocultos. Algunos estudios coinciden en que las técnicas de aprendizaje automático son adecuadas y efectivas para estudios de la demanda, ya que revelan patrones complejos (Bajari *et al.*, 2015).

Estos avances para examinar estas cuestiones relativas al comportamiento de los consumidores han motivado que recientes estudios las hayan comenzado a utilizar en diversos campos de la economía y de las finanzas: para encontrar patrones ocultos que pueden ser valiosos para la toma de decisiones en *marketing* bancario (Miguéis, Camanho y Borges, 2017) estimar las preferencias de los consumidores por productos tecnológicos (Chen, Honda y Yang, 2013), examinar las opciones de viaje (Hagenauer y Helbichy, 2017)/o modelar la respuesta del consumidor (Cui, Wong y Lui, 2006).

3. DATOS

3.1. Encuesta

El estudio empírico se basa en una encuesta realizada por la empresa IMOP para Funcas¹ sobre el uso de los servicios bancarios digitales, los medios de pago digitales y la adopción

¹ El presente estudio se enmarca en las actividades realizadas por el Observatorio de la Digitalización Financiera (ODF) de Funcas.

de los criptoactivos². Sigue la base metodológica de la *Survey of Consumer Payment Choice (SCPC)*, elaborada por el Banco de la Reserva Federal de Boston y usada ampliamente en la literatura académica para examinar cuestiones relativas al uso de medios de pagos (Schuh y Stavins, 2016; Kahn y Liñares-Zegarra, 2016). En concreto, fue realizada de forma *online* a 2.121 residentes en el territorio nacional –peninsular e insular– de entre 18 a 70 años.

Al tratarse de una encuesta *online*, es necesario advertir que el presente trabajo pretende examinar el grado de digitalización financiera de la población que ya tiene un determinado nivel de capacitación digital. Dicha elección metodológica no resta relevancia a las conclusiones que se puedan extraer del capítulo, ya que, según las estadísticas oficiales del Instituto Nacional de Estadística, el 91,8 % de la población española entre 16 y 74 años es usuaria, al menos semanalmente, de internet³.

El trabajo de campo tuvo lugar entre el 30 de noviembre y el 23 de diciembre de 2021, una vez superada la fase más dura de la pandemia. Para garantizar la representatividad de la muestra en el proceso de selección muestral se establecieron cuotas controladas por edad, sexo, comunidad de residencia y tamaño de la población. En términos agregados, el error muestral se estima en un $\pm 2,2$ % para un nivel de confianza del 95,5 %.

La relevancia del presente estudio en España tiene su justificación. Por un lado, España es un país que, de acuerdo con las estadísticas nacionales, ha superado la fase inicial de implantación de la banca electrónica. Todas las entidades financieras que operan en el país ofrecen a sus clientes la posibilidad de acceder a los distintos servicios financieros a través del canal digital. Además, una amplia base de la población española, cerca del 70 % de la población, ha accedido en los últimos tres meses a la banca digital, ya sea a través de la web de su banco o accediendo con la aplicación bancaria instalada en el móvil. Por otra parte, es uno de los países que ha experimentado una mayor aceleración en la digitalización de la población a raíz de la pandemia (Comisión Europea, 2022). Por estos motivos parece oportuno examinar el grado de digitalización financiera en un país donde los servicios bancarios digitales juegan un papel relevante, y más especialmente, a raíz de la pandemia de COVID-19.

3.2. Variables

La encuesta completa recoge un conjunto amplio de preguntas que dan lugar a distintas variables que podemos clasificar en:

- **Demografía, economía y trabajo:** en ellas se recopila información socioeconómica de los individuos como el sexo, edad, nivel de estudios, nivel de ingresos, población y comunidad autónoma de residencia.

² Un resumen de los principales resultados de dicha encuesta puede encontrarse en <https://www.funcas.es/articulos/digitalizacion-financiera-en-la-pospandemia-que-ha-cambiado/>

³ Encuesta sobre equipamiento y uso de tecnologías de información y comunicación en los hogares. INE. Disponible en: <https://www.ine.es/dynt3/inebase/es/index.htm?padre=8321capsel=8324>

- **Educación financiera y habilidades digitales:** recoge información sobre el nivel de educación financiera de los individuos y acerca de su nivel de capacitación para realizar determinadas actividades usando el canal digital (por ejemplo, si el individuo es capaz de descargar la aplicación móvil de su banco sin ayuda de un familiar o amigo).
- **Frecuencia de uso del canal digital:** recoge un conjunto de preguntas sobre la frecuencia con la que se accede a la banca *online*. También existen preguntas sobre la frecuencia con la que se acude a la sucursal de su entidad financiera.
- **Cuentas y servicios bancarios:** incluye preguntas sobre el número de cuentas bancarias y de otros servicios financieros que tiene contratados el individuo. Además, también se pregunta si alguna de dichas cuentas bancarias tiene un acceso exclusivamente digital.
- **Relación con la entidad bancaria:** recoge preguntas sobre el grado de relación que tiene el individuo con la que considera su principal entidad financiera.
- **Satisfacción con la entidad bancaria:** recopila la opinión del individuo acerca del grado de satisfacción con su entidad financiera principal.
- **Percepción canal digital:** incluye un conjunto de preguntas sobre la percepción que tiene el usuario sobre el coste, dificultad y seguridad de la banca electrónica.
- **Grado de uso del canal digital:** recoge preguntas sobre el tipo de servicios financieros –consulta de saldos, pagos, realización de transferencias y comunicación con el banco– que el individuo realiza a través del canal digital.

3.3. Muestra

El **cuadro 1** recoge la distribución muestral. Dichos porcentajes están muy correlacionados con los proporcionados por las estadísticas oficiales lo que justifica su representatividad.

Cuadro 1.

Distribución muestral

	Número	Porcentaje
<i>Sexo</i>		
Varón	1.078	50,83
Mujer	1.043	49,17
<i>Edad</i>		
De 18 a 29 años	414	19,52
De 30 a 39 años	359	16,93
De 40 a 49 años	547	25,79
De 50 a 59 años	392	18,48
De 60 a 70 años	409	19,28

Cuadro 1. (continuación)

Distribución muestral

	Número	Porcentaje
<i>Hábitat</i>		
Hasta 10.000 habitantes	316	14,90
De 10.001 a 50.000 habitantes	517	24,30
De 50.001 a 200.000 habitantes	528	24,89
De 200.001 a 500.000 habitantes	298	14,05
Más de 500.000 habitantes	462	21,78
<i>Nivel de estudios</i>		
Sin estudios	6	0,28
Estudios primarios o equivalentes	51	2,40
Enseñanza General Secundaria	366	17,26
Enseñanza de Formación Profesional	511	24,09
Universitarios	928	43,75
Posgrado o Doctorado	259	12,21
<i>Situación laboral</i>		
Trabaja	1.384	65,25
Pensionista/jubilado	297	14,00
En paro	212	10,00
Estudiante	182	8,58
Trabajo doméstico no remunerado	46	2,17
<i>Tamaño de la muestra</i>	2.121	100

3.4. Dimensiones de la digitalización financiera

Examinar el grado de digitalización financiera de un individuo es una tarea compleja, ya que el concepto de digitalización financiera es un concepto amplio. La interpretación de dicho concepto puede hacer que por “estar digitalizado” se entienda, simplemente tener acceso a la banca electrónica o hacer un uso intensivo del canal digital. Asimismo, la digitalización también puede englobar no solamente la frecuencia de uso, sino también la amplitud de las actividades realizadas *online*. De igual modo, con la revolución *Fintech* parte de dicho proceso de conversión en cliente financiero digital puede pasar por el uso de servicios financieros ofrecidos por entidades distintas a las entidades financieras tradicionales (neobancos, *fintech* o *bigtech*, entre otros). En definitiva, el proceso de digitalización financiera no es unidimensional, sino por el contrario, multidimensional. En un sentido amplio puede hablarse de varias dimensiones de la digitalización. Es por ello, que, en el presente estudio, para poder examinar con un mayor grado de profundidad el proceso de digitalización financiera se consideran explícitamente distintas dimensiones de la digitalización. En concreto, se examinan las siguientes cuatro dimensiones:

- *Adopción de la banca digital*: al examinar dicha dimensión se pretende conocer qué determina que los individuos se conviertan en usuarios frecuentes de los servicios bancarios a través del canal digital. El elemento clave que busca identificar dicha

dimensión es la frecuencia con la que el individuo hace uso de la banca digital. Dicha frecuencia de uso determinará su grado de adopción.

- *Alcance de uso de la banca digital*: con el alcance en el uso de la banca digital se busca conocer hasta qué punto los individuos llevan a cabo una pluralidad de actividades bancarias *online*. Realizar una distinción entre adopción y alcance es relevante, un individuo puede acceder muy frecuentemente a la banca electrónica únicamente para realizar una única actividad financiera. En este caso, hablaríamos de un individuo con un elevado grado de adopción de la banca digital, pero donde el alcance de su uso es muy limitado. En concreto, para medir dicha dimensión se consideran cuatro actividades financieras que pueden realizarse usando el canal digital: consultar saldos, realizar transferencias a terceros, realizar pagos de facturas o recibos y comunicarse con el banco.
- *Cliente de un banco exclusivamente digital*: con esta dimensión se pretende conocer qué determina que los individuos tengan contratada una cuenta bancaria con una entidad financiera que sea exclusivamente digital. En la medida en la que parte de la digitalización puede pasar por entidades nativas digitales, y no por las entidades financieras tradicionales, puede ser relevante explorar en profundidad dicha dimensión.
- *Adopción de medios de pagos no bancarios*: la actividad financiera donde se observa un mayor grado de digitalización es en la forma de pagar. Puesto que muchos de los nuevos medios de pagos son ofrecidos por entidades no bancarias (sin licencia bancaria), es relevante examinar cómo se produce la adopción de dichos pagos alternativos a los bancarios.

Para poder examinar cada una de las dimensiones en detalle, metodológicamente, los individuos son clasificados en diferentes categorías para cada una de las dimensiones analizadas. Respecto al grado de adopción de la banca digital, los 2.121 individuos de la muestra son clasificados en tres categorías. Aquel conjunto de individuos que no están digitalizados o lo están muy poco, ya que acceden a la banca *online* muy esporádicamente, es decir, una vez al año o casi nunca se consideran como “*No digitalizados (N)*”. Por su parte, identificamos como “*Medianamente digitalizados (M)*” a aquellos individuos que acceden a la banca *online* al menos una vez al mes o cada 15 días. Finalmente, aquellos individuos que acceden a la banca *online* casi todos los días o al menos una vez a la semana son categorizados como “*Ampliamente digitalizados (A)*”.

Por lo que respecta al alcance en el uso de la banca digital, los individuos son clasificados en cuatro categorías. Se consideran como “*No digitalizados (N)*” al conjunto de individuos que están fuera de la digitalización financiera porque no tienen acceso a la banca *online* o no realizan habitualmente (al menos semanalmente) ninguna actividad financiera. La categoría de “*Poco variado (P)*” la forman aquellos que solamente realizan una actividad financiera *online* habitualmente (al menos semanalmente). Aquellos individuos que realizan al menos dos actividades financieras *online* habitualmente (al menos semanalmente) son categorizados como “*Medianamente variado (M)*”. Por último, consideramos “*Omnidigital (O)*” a todo aquel

individuo que realiza al menos tres actividades financieras *online* habitualmente (al menos semanalmente).

La clasificación de los individuos en base a si son clientes de un banco exclusivamente digital es dicotómica. Se consideran “*No cliente (N)*” los que no son clientes de bancos exclusivamente digitales y “*Cliente (C)*” a los que sí son clientes. Del mismo modo, clasificamos a los individuos en función de si hacen uso de medios de pago a través de un proveedor no bancario (“*No usuario (N)*” vs. “*Usuario (S)*”).

4. METODOLOGÍA

Como se ha apuntado anteriormente, para tratar de dar respuesta a la pregunta de investigación del presente estudio se va a utilizar una metodología basada en el uso de técnicas de *machine learning*. En concreto, desde un punto de vista metodológico el trabajo se estructura en las siguientes etapas:

1. Predicción del grado de digitalización financiera de los consumidores después de la pandemia mediante el uso de algoritmos supervisados:
 - ▶ *random forest*
 - ▶ *extreme gradient boosting*
2. Elección del algoritmo que sea capaz de predecir con mayor precisión el grado de digitalización financiera de los consumidores después de la pandemia.
3. Identificación/Discriminación de los factores que contribuyen en mayor medida a predecir (factores de primer orden) la digitalización financiera de los consumidores.
4. Predicción del perfil digital de un cliente bancario representativo

La selección de estos dos algoritmos –*random forest* y *extreme gradient boosting*– está justificada por su bondad predictiva y su explicabilidad. Por un lado, como han señalado diversos estudios, estos dos modelos tienen una elevada capacidad predictiva. Además, al ser algoritmos menos complejos como los de *deep learning* o redes neuronales gozan de una mayor explicabilidad.

4.1. *Random forest*

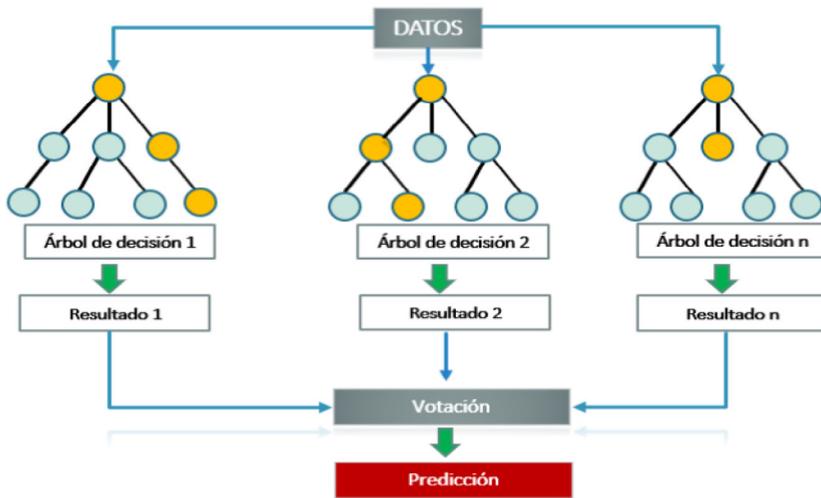
Random forest (bosque aleatorio) es un algoritmo de *machine learning* supervisado que se basa en la combinación de varios (muchos) árboles de decisión (Breiman, 2001). Dicha técnica combina una cantidad grande de árboles de decisión independientes probados sobre conjuntos de datos aleatorios con igual distribución. Para ello, el algoritmo sigue estos pasos:

1. Se genera un bosque de muchos árboles. Teniendo un conjunto N de observaciones diferentes, se elegirá una muestra N aleatoria con reemplazamiento.
2. Para cada nodo del árbol, se seleccionan m variables al azar de forma independiente entre todas las M variables posibles. Luego, en las m variables seleccionadas, encuentra la mejor división.
3. El algoritmo hace crecer cada árbol en la mayor medida posible.
4. Estos pasos se repiten en todos los árboles del conjunto, la predicción será la clase más votada entre todos los árboles del bosque.

La [figura 1](#) ilustra el funcionamiento que sigue dicho algoritmo.

Figura 1.

Representación simplificada del *random forest*



Como han señalado estudios previos, la utilización del algoritmo del *random forest* presenta un conjunto de ventajas metodológicas con respecto a otros algoritmos de *machine learning* supervisados. Entre estas ventajas destacan que:

- Es una técnica fácil de interpretar, estable, que por lo general presenta buenas coincidencias con los resultados obtenidos con otras técnicas de *machine learning*.
- Se puede utilizar en tareas de regresión o de clasificación.
- El hecho de que pueda usarse para tareas de clasificación y regresión, combinado con su naturaleza no lineal, lo hace altamente adaptable a una variedad de datos y situaciones.

- Puede manejar cientos de predictores sin excluir ninguno. Además, es capaz de identificar cuáles son los predictores más importantes, por lo que esta técnica también se utiliza para reducir el número de variables empleadas en un estudio (reducción de dimensionalidad).
- Debido a la utilización de múltiples árboles de decisión, la varianza de la predicción disminuye respecto a un solo árbol de decisión, lo que reduce la posibilidad de obtener un modelo sobreajustado.
- Se trata de un algoritmo cuyo entrenamiento es más simple en comparación con otras técnicas más complejas (redes neurales o *deep learning*), pero con un rendimiento similar.

Las ventajas que presenta el *random forest* para resolver problemas complejos ha motivado que sea utilizado en diversos campos:

- *Medicina*: para analizar historiales clínicos a fin de identificar enfermedades potenciales en los pacientes (Masetic y Subasi, 2016).
- *Sector bancario*: para detección de fraudes (Namiy Shajari, 2018) y clasificación de clientes para otorgamiento de crédito (Trivedi, 2020).
- *Sector financiero en sentido amplio*: para pronosticar comportamientos futuros de los mercados financieros (Ciner, 2019).
- *Marketing/Comportamiento del consumidor*: para pronosticar si un cliente comprará, o no, cierto producto (Miguéis, Camanho y Borges, 2017; Hagenauer y Helbich, 2017).

4.2. *Extreme gradient boosting*

Extreme gradient boosting es un algoritmo de *machine learning* supervisado que se basa en la generación de múltiples modelos secuenciales de predicción, en los que cada nuevo modelo toma el resultado del modelo anterior, haciendo que los resultados obtenidos en cada secuencia sean cada vez más robustos, y, por tanto, obteniendo en cada iteración resultados más exactos. Se trata de una técnica de *machine learning* que surge de la idea de que, modelos sencillos mejorados pueden dar lugar a buenos modelos. Para ello, el algoritmo sigue estos pasos (ilustrados en la [figura 2](#)):

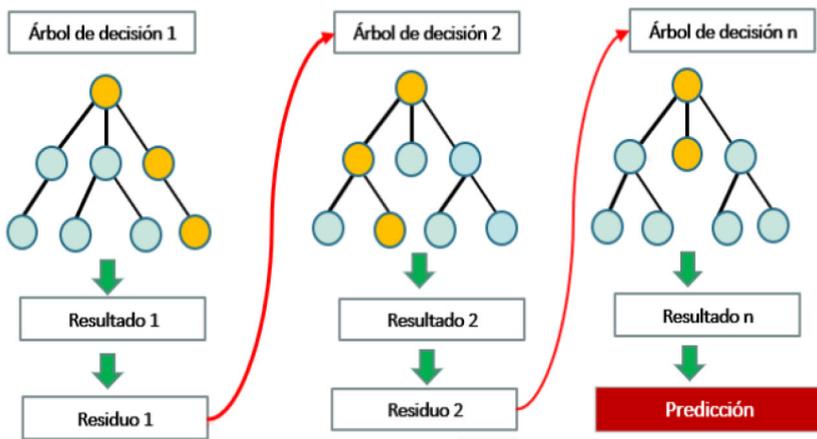
1. Durante el entrenamiento, los parámetros de cada modelo débil son ajustados iterativamente tratando de encontrar el mínimo de una función objetivo, que puede ser la proporción de error en la clasificación, el área bajo la curva (AUC), la raíz del error cuadrático medio (RMSE) o alguna otra.
2. Cada modelo es comparado con el anterior, Si un nuevo modelo tiene mejores resultados, entonces se toma este como base para realizar nuevas modificaciones. Si, por el

contrario, tiene peores resultados, se regresa al mejor modelo anterior y se modifica ese de una manera diferente.

- Este proceso se repite hasta llegar a un punto en el que la diferencia entre modelos consecutivos es insignificante, lo cual nos indica que hemos encontrado el mejor modelo posible, o cuando se llega al número de iteraciones máximas definido por el usuario.

Figura 2.

Representación simplificada del *extreme gradient boosting*



Al igual que ocurre con el *random forest*, el *extreme gradient boosting* también presenta un conjunto de bondades metodológicas que motivan su uso en la literatura académica, entre ellas:

- Puede utilizarse con valores faltantes (*missing values*). Cuando encuentra un valor faltante en un nodo, intenta la división de la mano izquierda y derecha, y aprende el camino que conduce a una mayor pérdida para cada nodo. Luego hace lo mismo cuando trabaja en los datos de prueba.
- En comparación con otros métodos de aumento de gradiente (*gradient boosting*), el aumento de gradiente extremo utiliza una formalización de modelo más regularizada para controlar el sobreajuste.
- Es apropiado para base de datos grandes, donde el número de variables sea menor que el número de observaciones.
- Es más eficiente, requiriendo un menor tiempo de computación que otros algoritmos supervisados.

En los últimos años, también viene apreciándose como el uso del *extreme gradient boosting* también se está extendiendo a numerosos campos como:

- *Medicina*: para analizar historiales clínicos a fin de diagnosticar el cáncer (Ma *et al.*, 2020).
- *Sector financiero*: para predecir crisis bancarias (Carmona, Climent y Momparler, 2019).
- *Marketing*: para predecir la popularidad *online* (Nguyen, 2020).
- *Energía*: para predecir crisis en el mercado del gas natural (Zhang y Hamori, 2020).

5. RESULTADOS

5.1. *Random forest vs. extreme gradient boosting*

Con el fin de seleccionar la técnica con el mayor grado de precisión, siendo consistente con el estándar utilizado en la literatura de *machine learning*, se designa aleatoriamente al 70 % de los datos como datos de entrenamiento (1.485 observaciones) y al 30 % restante (636 observaciones) como de prueba. Utilizamos dicho umbral ya que la literatura empírica ha demostrado que los mejores resultados se obtienen si la división de los datos está en el marco del 20-30 % de los datos para pruebas y del 70-80 % restante para entrenamiento. Al hacerlo, podemos determinar la precisión del modelo asegurando que el algoritmo en realidad está encontrando patrones reales en los datos y que no se está sobreajustando. El grado de precisión de ambos modelos se calcula como el porcentaje de predicciones correctas (el número de puntos de datos pronosticados correctamente en relación al número total de datos).

Como se puede observar en el **cuadro 2**, para todas las dimensiones consideradas, el *extreme gradient boosting* es el algoritmo de *machine learning* que reporta los mayores porcentajes de predicciones correctas. Para aquellas dimensiones donde los individuos están clasificados en más de dos categorías –grado de digitalización bancaria y omnidigitaliza-

Cuadro 2.

Precisión del *random forest* y del *extreme gradient boosting*

	<i>Random forest</i>		<i>Extreme gradient boosting</i>	
	% de aciertos	95 % I.C	% de aciertos	95 % I.C
Grado de digitalización bancaria	79,73	(76,30 – 82,88)	79,96	(78,19 – 81,65)
Omnidigitalización	79,01	(76,86 – 81,22)	80,01	(78,24 – 81,69)
Cliente banco excl. digital	81,57	(79,52 – 83,49)	85,38	(83,81 – 86,86)
Pagos no bancarios	66,11	(62,18 – 69,89)	71,52	(69,55 – 73,44)

ción– consideramos que el algoritmo ha acertado si ha sido capaz de predecir exactamente la categoría de entre todas las posibles. En concreto, el *extreme gradient boosting* predice con una precisión del 79,96 % el grado de digitalización bancaria y con una precisión del 80,01 % la diversidad del uso digital de la banca en línea. Además, es capaz de predecir con una precisión del 85,38 % qué usuarios son clientes de bancos exclusivamente digitales y con un 71,52 % quiénes usan medios de pagos no bancarios. Aunque no han sido reportados por cuestiones de espacio, las dos técnicas de *machine learning* empleadas presentan unos porcentajes de predicciones correctas significativamente superiores a la obtenidas usando modelos de elección discreta (*ordered logit and logit*). Al usar estos modelos econométricos, en la mayor parte de las dimensiones, el porcentaje de predicciones correctas se encuentra cercano al 65 %.

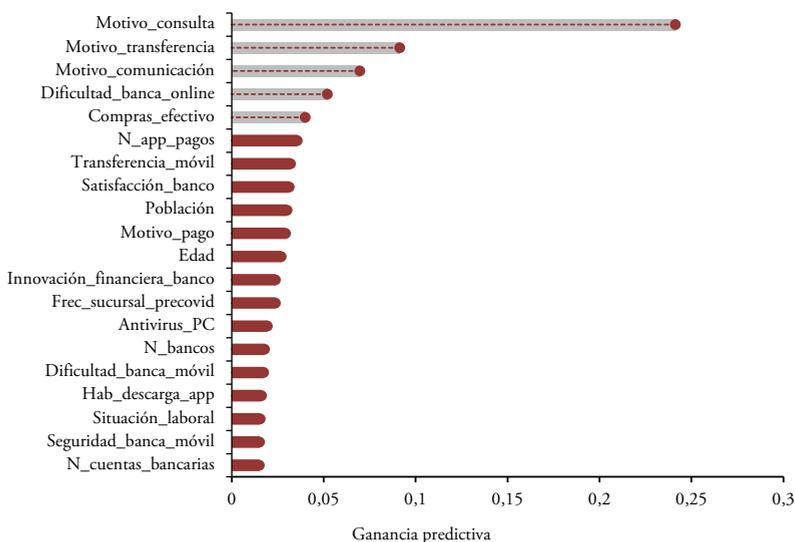
Puesto que el *extreme gradient boosting* es la técnica que presenta el mayor porcentaje de predicciones correctas, utilizaremos dicha técnica para identificar los factores que contribuyen en mayor medida a predecir (factores de primer orden) la digitalización financiera de los consumidores.

5.2. ¿Qué factores predicen mejor el grado de digitalización financiera?: importancia

Para tratar de discriminar cuáles son aquellos factores que predicen mejor el grado de digitalización financiera, en cada una de las dimensiones examinadas, vamos a calcular la

Figura 3.

Importancia – Grado de digitalización financiera

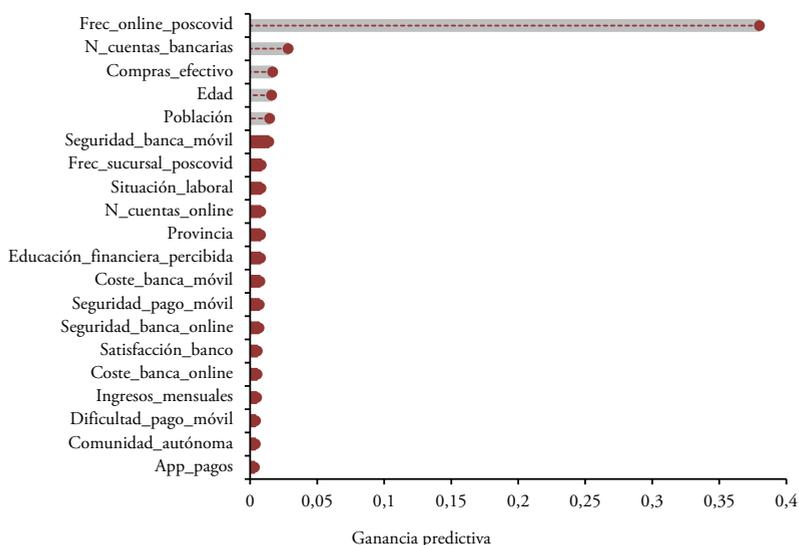


“ganancia predictiva” de cada uno de los factores (variables) considerados. Podemos definir la ganancia predictiva como la contribución relativa de cada factor a la capacidad predictiva del modelo. Un valor más alto de esta métrica implica que dicho factor es más importante para generar una predicción. En definitiva, con esta métrica pueden identificarse cuáles son las características que presentan una mayor importancia para predecir el grado de digitalización financiera.

La **figura 3** muestra los veinte factores que presentan una mayor ganancia predictiva (ordenados de mayor a menor) para predecir correctamente el grado de adopción de la banca digital. Como puede observarse, los principales factores que permiten clasificar a los individuos en función de su grado de adopción de la banca digital son la necesidad/utilidad percibida de los consumidores sobre la banca digital para consultar saldos, transferir dinero y comunicarse/relacionarse con el banco. En especial, destaca la consulta de saldos, lo que puede indicar que la adopción pasa primeramente por la necesidad de usar la banca electrónica para realizar tareas consultivas o informativas respecto a las finanzas personales. También puede observarse que, la percepción acerca de la dificultad de uso de la banca *online* es un factor que predice ampliamente el grado de digitalización financiera. Otros factores como las percepciones o ideas que se tienen acerca del coste y seguridad de la banca *online* no explican el grado de digitalización financiera. Asimismo, aquellos factores socioeconómicos como la edad, el lugar de residencia (rural vs. urbano), el nivel de ingresos o la situación laboral parecen revelarse como factores de segundo orden para predecir el grado de adopción de la banca digital por parte de los individuos.

Figura 4.

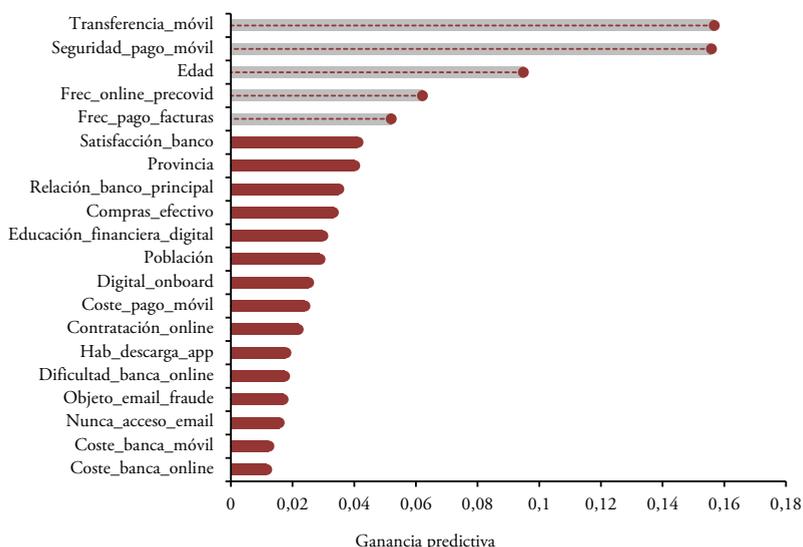
Importancia – Alcance de la digitalización financiera



La **figura 4** muestra la importancia relativa para predecir correctamente el alcance en el uso de la banca digital. Como puede apreciarse, el principal factor, y casi único factor, que predice que un individuo pueda utilizar la banca *online* para realizar una pluralidad de actividades financieras es la frecuencia de acceso/uso de la banca *online*. Este resultado sugiere que la frecuencia en el uso de la banca *online* permitirá discriminar ampliamente quiénes son aquellos que acometen un uso más diversificado de la banca electrónica. En otras palabras, dicho resultado sugiere que no es posible alcanzar un elevado grado de diversificación de uso de la banca *online* si no existe previamente el hábito de acceder con una elevada frecuencia a la banca electrónica. Otros factores como las percepciones o ideas que se tienen acerca del coste, dificultad y seguridad de la banca digital no explican la diversificación en el uso de la banca *online*.

Figura 5.

Importancia – Cliente de un banco exclusivamente digital



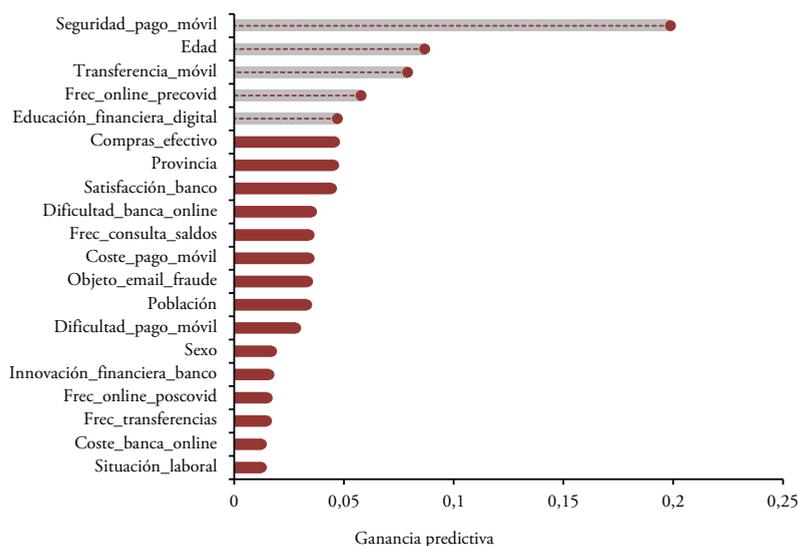
Por su parte, la **figura 5** recoge la importancia relativa de los factores que predicen que un individuo se convierta en un cliente de una entidad bancaria exclusivamente digital. Dicha figura revela que los principales factores que predicen que un consumidor sea cliente de un banco 100 % digital son, principalmente, la necesidad de transferir dinero a otros con el móvil y la percepción que se tenga acerca de la seguridad que tiene los pagos con el móvil. La relevancia que tienen los factores relacionados con el móvil y con los pagos parecen indicar que el proceso de conversión en cliente de un banco digital pasa por utilizar el móvil/*smartphone* como dispositivo para gestionar las finanzas, y especialmente para transferir dinero o para pagar. En este caso, factores como la edad sí parecen ser muy relevantes para predecir si un consumidor es cliente de un banco 100 % digital, lo que sugiere que los clientes de estos ban-

cos digitales pueden concentrarse en determinados segmentos de población. Además del grado de adopción de la banca digital, también aparecen como factores de segundo orden el grado de satisfacción que el consumidor tiene con su entidad financiera.

Los principales factores que predicen el uso de medios de pagos no bancarios están representados en la **figura 6**. Como se puede observar, la percepción acerca de la seguridad que existe para realizar pagos con el móvil es el primer factor que predice que un consumidor pague con medios de pagos ofrecidos por entidades no bancarias. Además, la edad también juega un papel importante para predecir el uso de medios de pagos no bancarios, lo que sugiere que puede existir una brecha en el uso de medios de pagos no bancarios por grupos de edades. También se observa cómo el nivel de educación financiera juega un papel relevante en el uso de medios de pagos no bancarios. Este resultado sugiere que carencias en el nivel de educación financiera pueden derivar en diferencias en el grado de uso de medios de pagos no bancarios.

Figura 6.

Importancia – Usuario de pagos no bancarios



5.3. Tipología de factores

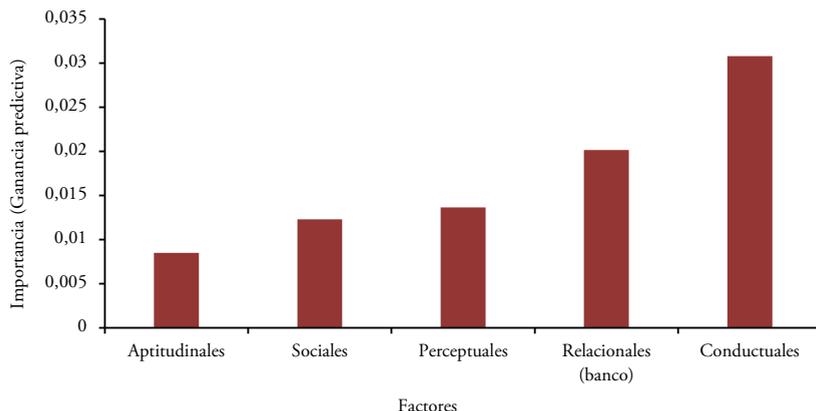
Para tratar de completar el ejercicio acerca de qué características presentan un mayor poder discriminatorio para predecir el grado de digitalización financiera, basándonos en la literatura académica, los distintos determinantes del grado de digitalización financiera los agrupamos en cinco tipologías de factores. El objetivo es proporcionar una imagen más amplia de qué está detrás de cada una de las diferentes dimensiones de la digitalización consideradas. En concreto, todos los factores (características) se agrupan en las siguientes:

- **Aptitudinales:** hacen referencia a aquellos determinantes referidos a la capacidad/habilidad que tiene cierta persona para poder desempeñarse competentemente en una actividad (ejemplo: habilidad para descargar una *app* bancaria sin ayuda de familiares o amigos).
- **Conductuales:** hacen referencia a aquellos determinantes referidos a la realización de determinadas conductas o actividades por parte de un individuo (ejemplo: verificar el cierre de la *app* bancaria o el porcentaje de compras que realiza en efectivo).
- **Relacionales (banco):** hacen referencia a aquellos determinantes referidos a la relación/afección que el individuo tiene con el sector bancario, en particular, con su entidad financiera de referencia (ejemplo: porcentaje de operaciones que realiza con su entidad financiera principal).
- **Sociales:** hacen referencia a aquellos determinantes referidos al ámbito socioeconómico y demográfico del individuo (ejemplo: sexo, población, nivel de ingresos).
- **Perceptuales:** hacen referencia a aquellos determinantes referidos a la percepción que el individuo tiene acerca del canal digital (ordenador y móvil) en el contexto bancario (ejemplo: percepción acerca del coste de la banca móvil).

Para cada una de las categorías, calculamos la importancia relativa –basándonos en la ganancia predictiva– con el objeto de conocer qué tipo de factores son los más relevantes para cada una de las dimensiones de la digitalización. Un mayor grado de ganancia predictiva indica que ese conjunto de factores es más relevante para predecir dicha dimensión.

Figura 7.

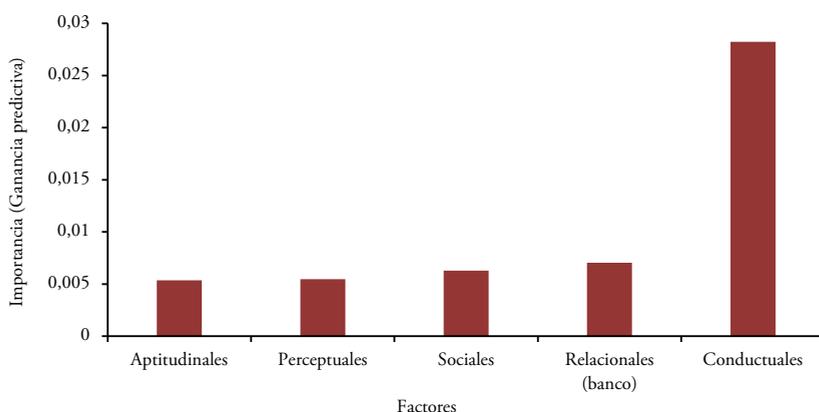
Importancia por tipología de factores – Grado de digitalización financiera



Respecto a las dos dimensiones que tienen que ver con la digitalización bancaria (figuras 7 y 8) –adopción y el alcance de uso de la banca digital– se observa que los factores conductuales, es decir, los hábitos o costumbres adquiridas por los individuos sobre la forma de realizar actividades financieras, son los más relevantes seguidos de los relacionales. Por otra parte, la mayor relevancia de los factores relacionales frente a otros como los perceptuales y/o sociales sugieren que el grado de digitalización pasa en mayor medida por la intensidad de relaciones que los usuarios tienen con su banca en comparación a la percepción que puedan tener acerca de la banca electrónica o móvil. Estas figuras también revelan que, al menos para el grueso de la población, el nivel de aptitudes para usar el canal digital parece tener poca importancia para predecir el grado de adopción de la banca digital y la diversificación de su uso.

Figura 8.

Importancia por tipología de factores – Alcance de digitalización financiera



Por otra parte, en relación a las otras dos dimensiones que hacen referencia al grado de digitalización financiera al margen del sector bancario tradicional –cliente exclusivo digital y uso de medios de pago no bancarios (figuras 9 y 10)– se observa que los factores sociales –edad, población, nivel de estudios, nivel de ingresos, situación laboral– son los más relevantes para predecir quiénes son los usuarios de medios de pago no bancarios como los clientes de bancos 100 % digitales.

Este resultado sugiere que tanto los usuarios de los bancos 100 % digitales, o también llamados “neobancos”, y de medios de pago no bancarios, ofrecidos por compañías *bigtech* (ApplePay, AmazonPay, etc.) o *fintech* (Verse, PayPal, etc.), pueden concentrarse en determinados segmentos de población muy concreta. Además, se puede apreciar cómo los factores perceptuales o relacionales juegan un papel secundario a la hora de explicar la transición de ser cliente de un banco tradicional a ser cliente/usuario de un neobanco o de una entidad no bancaria.

Figura 9.

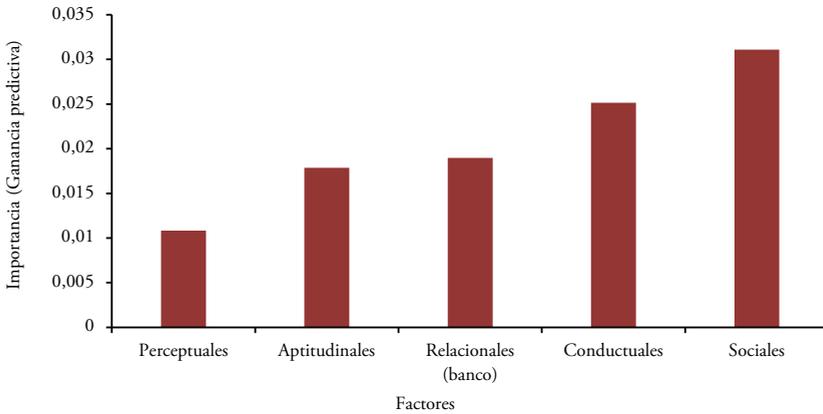
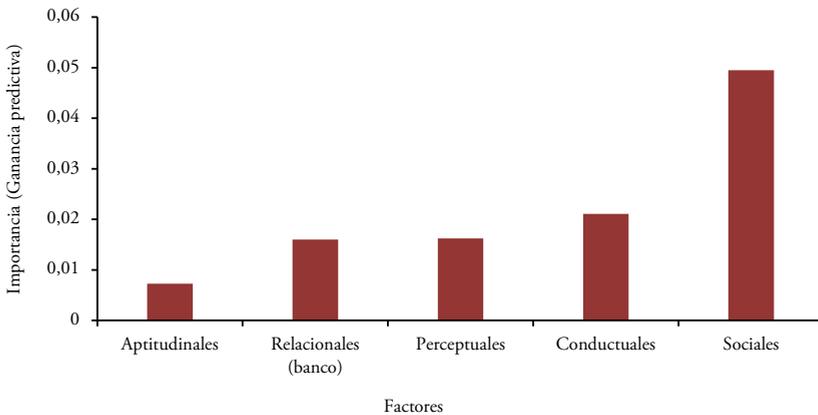
Importancia por tipología de factores – Cliente de un banco exclusivamente digital

Figura 10.

Importancia por tipología de factores – Usuario de pagos no bancarios**5.4. El perfil digital de un cliente bancario representativo**

A partir de los datos de la encuesta, tratamos de predecir cuál es el perfil digital de un cliente bancario representativo. Para ello:

1. Para cada una de las variables empleadas se calcula la mediana para conocer el comportamiento de un individuo representativo.

2. Utilizando el *extreme gradient boosting* –que es el algoritmo con el mayor nivel de precisión– se predice cuál sería la categoría asociada a cada una de las cuatro dimensiones consideradas.

Tras seguir este procedimiento, se puede concluir que el perfil digital de un cliente bancario representativo se corresponde con un individuo:

- Ampliamente digitalizado: accede a la banca *online* casi todos los días o al menos una vez a la semana.
- Omnidigital: realiza al menos tres actividades financieras *online* habitualmente (al menos semanalmente).
- Que no acude a entidades exclusivamente digitales.
- Que es usuario de medios de pago no bancarios.

Este resultado confirma el elevado grado de digitalización bancaria del español medio, ya que hace un uso frecuente y variado de la banca digital. Además, también se aprecia una adopción significativa de medios de pagos no bancarios. Si bien, el consumidor representativo español no es cliente de entidades no bancarias, sino que los bancos tradicionales siguen siendo los principales proveedores de servicios financieros.

6. CONCLUSIONES

El salto digital de las sociedades se ha visto acentuado con la pandemia. El COVID-19 y las medidas de distanciamiento social adoptadas han provocado que las personas hayan adoptado el canal digital para realizar gestiones y actividades que, hasta hace poco, realizaban presencialmente. Este salto digital también ha impregnado el ámbito financiero, desde la realización de pagos hasta la contratación y gestión de las finanzas personales. La pandemia ha acelerado el grado de digitalización financiera de la sociedad. Si bien, a pesar del avance digital, existen diferencias en el uso del canal digital entre distintos segmentos de población. En este contexto, y una vez superada la fase más dura de la pandemia, resulta relevante examinar los factores que permiten predecir por qué algunos consumidores han avanzado más su grado de digitalización financiera. El conocimiento de dichos factores –sociales, conductuales, aptitudinales, perceptuales y relacionales– permite entender mejor cuáles pueden ser las trabas o barreras que pueden limitar la digitalización financiera de la sociedad.

Este estudio pretende profundizar en el conocimiento del proceso de digitalización financiera haciendo uso de técnicas de aprendizaje automático (*random forest* y *extreme gradient boosting*). Las ventajas que ofrecen estas técnicas de *machine learning* en relación con otras metodologías es que permiten conocer de una forma más detallada los patrones que afectan al comportamiento digital de los consumidores en lo que respecta a la gestión de sus finanzas personales. En concreto, el presente trabajo examina las distintas dimensiones del proceso de digitalización financiera. Por una parte, examina la digitalización banca-

ria al investigar los factores que predicen la adopción y el alcance de uso de la banca digital. Por otro lado, también analiza el grado de digitalización no-bancaria al examinar los determinantes que predicen la conversión en cliente de un banco exclusivamente digital y la adopción de medios de pagos no bancarios. El examen diferenciado de cada una de estas dimensiones ayuda a dar una respuesta más específica y detallada a las diferentes aristas que plantea el proceso de digitalización financiera. Para ello, el trabajo se basa en una encuesta sobre el uso de los servicios bancarios digitales, los medios de pago digitales y la adopción de los criptoactivos realizada en diciembre de 2021 por 2.121 individuos de entre 18 a 70 años residentes en España.

El trabajo concluye que, en comparación con otras técnicas, los dos algoritmos empleados ofrecen mejores predicciones acerca del grado de digitalización financiera de los consumidores. Además, los principales factores que predicen el grado de digitalización financiera son la necesidad/utilidad percibida de los consumidores sobre la banca digital para consultar saldos, transferir dinero y comunicarse/relacionarse con el banco. El principal factor, y casi único factor, que predice que un individuo pueda utilizar la banca digital para realizar una pluralidad de actividades financieras es la frecuencia de acceso/uso de la banca *online*. Por otra parte, los principales factores que predicen que un consumidor sea cliente de un banco 100 % digital son, principalmente, la necesidad de transferir dinero a otros con el móvil y la percepción que se tenga acerca de la seguridad que tiene los pagos con el móvil. Sin embargo, en lo que respecta a la adopción de medios de pago no bancarios, la percepción acerca de la seguridad que ofrece el móvil como método de pago es el primer factor que predice que un consumidor pague con medios de pagos ofrecidos por entidades no bancarias. Además, el trabajo evidencia el elevado grado de digitalización financiera de la sociedad española, ya que el cliente bancario representativo hace un uso frecuente y variado de la banca digital, a lo que se une, que paga con medios de pagos digitales no bancarios.

Estos resultados pueden tener importantes implicaciones para el conjunto de la industria financiera, ya que evidencian diferencias en el proceso de digitalización financiera en función de quién es el proveedor de los servicios financieros (banco tradicional vs. entidad bancaria digital). Para las entidades bancarias, estos resultados ponen de manifiesto la necesidad de avanzar hacia aplicaciones bancarias personalizadas que mejoren la actual experiencia de cliente con el objetivo de que éstos puedan en todo momento percibir la banca digital como un elemento que les ayuda a realizar sus actividades financieras básicas (consulta de saldos, realización de transferencias y comunicarse con su banco). Además, entender el proceso de digitalización bancaria es relevante, ya que dicho proceso puede generar externalidades positivas que van más allá del propio ámbito bancario. En muchos casos, se observa cómo algunos segmentos de población han avanzado en sus competencias digitales gracias al uso de la banca electrónica. El aprendizaje que supone la descarga de la aplicación móvil del banco y su uso ha facilitado que el mismo usuario pueda realizar otras actividades digitales –por ejemplo, pedir cita *online* a una Administración pública o realizar compras por internet.

Referencias

- ALDÁS-MANZANO, J., LASSALA-NAVARRÉ, C., RUIZ-MAFÉ, C. y SANZ-BLAS, S. (2009). The role of consumer innovativeness and perceived risk in online banking usage. *International Journal of Bank Marketing*, 27, pp. 53–75.
- BAJARI, P., NEKIPELOV, D., RYAN, S. P. y YANG, M. (2015). Machine Learning Methods for Demand Estimation. *American Economic Review*, 105, pp. 481–485.
- BREIMAN, L. (2001). Random forests. *Machine learning*, 45, pp. 5–32.
- CARBÓ-VALVERDE, S., CUADROS-SOLAS, P. y RODRÍGUEZ-FERNÁNDEZ, F. (2020). A machine learning approach to the digitalization of bank customers: Evidence from random and causal forests. *PlosOne*, 15(10).
- CARBÓ-VALVERDE, S., CUADROS-SOLAS, P. y RODRÍGUEZ-FERNÁNDEZ, F. (2021). Digitalización financiera y COVID-19: evidencia empírica. *Papeles Economía Española*, 170, pp. 143–156.
- CHEN, H. Q., HONDA, T. y YANG, M. C. (2013). Approaches for Identifying Consumer Preferences for the Design of Technology Products: A Case Study of Residential Solar Panels. *Journal of Mechanical Design*, 135, 061007 (2013).
- CINER, C. (2019). Do industry returns predict the stock market? A reprise using the random forest. *The Quarterly Review of Economics and Finance*, 72, pp. 152–158.
- COMISIÓN EUROPEA. (2022). Digital Economy and Society Index (DESI).
- CORREIA LOUREIRO, S. M., RÜDIGER KAUFMANN, H. y RABINO, S. (2014). Intentions to use and recommend to others. *Online Information Review*, 38, pp. 186–208.
- CUI, G., WONG, M. L. y LUI, H. K. (2006). Machine learning for direct marketing response models: Bayesian networks with evolutionary programming. *Management Science*, 52, pp. 597–612.
- ESTRELLA-RAMON, A., SÁNCHEZ-PÉREZ, M. y SWINNEN, G. (2016). How customers' offline experience affects the adoption of online banking. *Internet Research*, 26, pp. 1072–1092.
- FU, J. y MISHRA, M. (2022). Fintech in the time of COVID-19: Technological adoption during crises. *Journal of Financial Intermediation*, 50, 100945.
- HAGENAUER, J. y HELBICH, M. (2017). A comparative study of machine learning classifiers for modeling travel mode choice. *Expert Systems with Applications*, 78, pp. 273–282.
- HERNÁNDEZ-MURILLO, R., LLOBET, G. y FUENTES, R. (2010). Strategic online banking adoption. *Journal of Banking and Finance*, 34, pp. 1650–1663.
- HITT, L. M. y FREI, F. X. (2002). Do Better Customers Utilize Electronic Distribution Channels? The Case of PC Banking. *Management Science*, 48, pp. 732–748.
- HONKA, E., HORTA, A. y VITORINO, M. A. (2017). Advertising, Consumer Awareness and Choice: Evidence from the U.S. Banking Industry. *RAND Journal of Economics*, 48, pp. 611–646.
- JÜNGER, M. y MIETZNER, M. (2020). Banking goes digital: The adoption of FinTech services by German households. *Finance Research Letters*, 34, 101260.
- KAHN, C. M. y LIÑARES-ZEGARRA, J. M. (2016). Identity Theft and Consumer Payment Choice: Does Security Really Matter? *Journal of Financial Services Research*, 50, pp. 121–159.
- KOULAYEV, S., RYSMAN, M., SCHUH, S. y STAVINS, J. (2016). Explaining adoption and use of payment instruments by US consumers. *RAND Journal of Economics*, 47, pp. 293–325.
- LECUN, Y., BENGIO, Y. y HINTON, G. (2015). Deep learning. *Nature*, 521, pp. 436–444.

- LIN, W. R., WANG, Y. H. y HUNG, Y. M. (2020). Analyzing the factors influencing adoption intention of internet banking: Applying DEMATEL-ANP-SEM approach. *PLoS One*, 15, pp. 1–25.
- MA, B. *et al.* (2020). Diagnostic classification of cancers using extreme gradient boosting algorithm and multinomics data. *Computers in Biology and Medicine*, 121, 103761.
- MASETIC, Z. y SUBASI, A. (2016). Congestive heart failure detection using random forest classifier. *Comput. Computer Methods and Programs in Biomedicine*, 130, pp. 54–64.
- MIGUÉIS, V. L., CAMANHO, A. S. y BORGES, J. (2017). Predicting direct marketing response in banking: Comparison of class imbalance methods. *Service Business*, 11, pp. 831–849.
- MONTAZEMI, A. R. y QAHRI-SAREMI, H. (2015). Factors affecting adoption of online banking: A meta-analytic structural equation modeling study. *Information and Management*, 52, pp. 210–226.
- NAMI, S. y SHAJARI, M. (2018). Cost-sensitive payment card fraud detection based on dynamic random forest and k-nearest neighbors. *Expert Systems with Applications*, 110, pp. 381–392.
- NGUYEN, L. T. K., CHUNG, H. H., TULIAO, K. V. y LIN, T. M. Y. (2020). Using XGBoost and Skip-Gram Model to Predict Online Review Popularity. *SAGE Open*, 10.
- POUSTTCHI, K. y DEHNERT, M. (2018). Exploring the digitalization impact on consumer decision-making in retail banking. *Electronic Markets*, 28, pp. 265–286.
- SCHUH, S. y STAVINS, J. (2016). How Do Speed and Security Influence Consumers' Payment Behavior? *Contemporary Economic Policy*, 34, pp. 595–613.
- STAVINS, J. (2020). Credit Card Debt and Consumer Payment Choice: What Can We Learn from Credit Bureau Data? *Journal of Financial Services Research*, 58, pp. 59–90.
- SZOPIŃSKI, T. S. (2016). Factors affecting the adoption of online banking in Poland. *Journal of Business Research*, 69, pp. 4763–4768.
- TRIVEDI, S. K. (2020). A study on credit scoring modeling with different feature selection and machine learning approaches. *Technology in Society*, 63, 101413.
- WITTEN, I. H., FRANK, E. y HALL, M. A. (2019). *Data Mining: Practical Machine Learning Tools and Techniques (Third Edition)*. *Morgan Kaufmann*, 53 (Morgan Kaufmann, 2019).
- YUSUF DAUDA, S. y LEE, J. (2015). Technology adoption: A conjoint analysis of consumers' preference on future online banking services. *Information Systems*, 53, pp. 1–15.
- ZHANG, W. y HAMORI, S. (2020). Do machine learning techniques and dynamic methods help forecast US natural gas crises? *Energies*, 13(9), 2371

CAPÍTULO II

Negociación de alta frecuencia y calidad del mercado: revisión de una década de investigación

Roberto Pascual*

Revisamos una década de investigación académica sobre el HFT para evaluar su impacto sobre la calidad de los mercados financieros. Además de caracterizar el HFT y sus estrategias canónicas, examinamos cómo cada una de ellas afecta a la liquidez y a la eficiencia en precios. Concluimos que el efecto neto del HFT ha sido positivo. No obstante, el HFT oportunista podría tener externalidades negativas, tanto sobre los proveedores de liquidez como sobre la negociación informada. Además, el HFT podría aumentar el riesgo sistemático y reducir la eficiencia en precios a largo plazo al desincentivar la adquisición de nueva información.

Palabras clave: HFT, negociación algorítmica, mercado bursátil, liquidez, formación de precios, eficiencia en precios, microestructura.

* El autor agradece el apoyo financiero del Ministerio de Ciencia, Innovación y Universidades, de la Agencia Estatal de Investigación y del Fondo Europeo de Desarrollo Regional a través del proyecto PRPPID2021-125317NB-I00. El autor agradece también a David Abad, Carole Comerton-Forde, Álvaro Escribano, Magdalena Massot, Rebeca Méndez-Durón, y José Yagüe sus comentarios sobre versiones preliminares del trabajo. Toda la responsabilidad sobre el contenido de este trabajo es del autor.

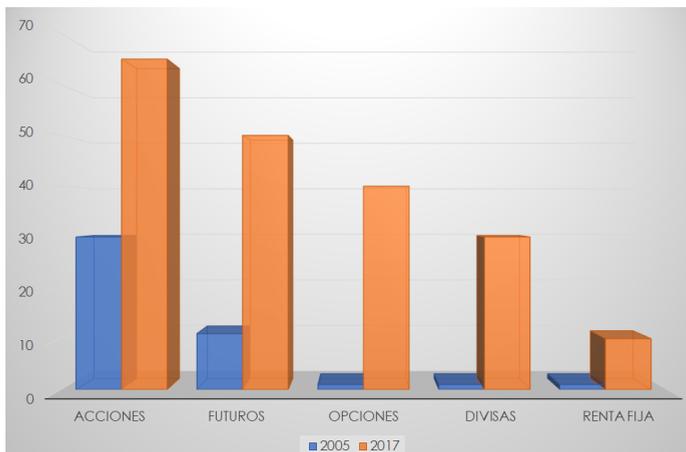
1. INTRODUCCIÓN

En las últimas décadas los mercados financieros han experimentado una profunda transformación tecnológica. Los mercados de contacto físico (o parqués) han quedado relegados a un papel secundario (Hendershott y Moulton, 2011), mientras que el grueso de la negociación se realiza a través de plataformas electrónicas. En éstas, los participantes envían sus instrucciones de negociación (órdenes) al servidor del mercado (*host*) de forma remota y éste se encarga de ejecutarlas siguiendo unas reglas preestablecidas. Estos mercados virtuales traen consigo una creciente automatización, esto es, la sustitución del hombre por la máquina en diferentes fases del proceso, como por ejemplo en la gestión del flujo de órdenes, el emparejamiento de órdenes de compra y venta, la fijación del precio de transacción, la liquidación de posiciones o la transmisión de la información tanto pre-transacción (liquidez) como post-transacción (negociación).

Los operadores más sofisticados explotan el potencial de los mercados virtuales buscando formas de negociar más eficientes. De este modo surge la negociación algorítmica, o *algorithmic trading* (AT), el uso de programas de ordenador (algoritmos) para, de forma automática tomar decisiones, implementar estrategias y gestionar órdenes. El crecimiento del AT durante las últimas décadas ha sido exponencial, como se muestra en la [figura 1](#). En el año 2017, el 65 % del volumen global negociado en acciones era atribuible al AT, doblando su peso respecto al año 2005. Pero el AT no se limita sólo a negociar acciones. La [figura 1](#) ilustra el rápido crecimiento del AT en mercados de derivados y divisas, siendo prácticamente inexistente en 2005. Centrándonos en el caso de los mercados bursátiles, la [figura 2](#) muestra que la

Figura 1.

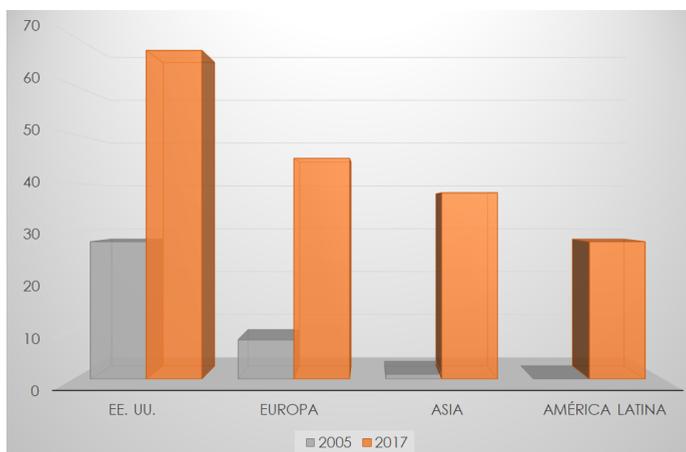
Cuota global del AT (% turnover)



Fuentes: Hong Kong Institute for Monetary and Financial Research (2021).

Figura 2.

Cuota del AT en acciones por región (% turnover)



Fuentes: Hong Kong Institute for Monetary and Financial Research (2021).

presencia del AT es mucho mayor en aquellas regiones donde se desarrolló inicialmente, es decir, EE. UU. (65 %) y Europa (45 %), aunque se está expandiendo rápidamente en Asia y Latinoamérica.

Al mismo tiempo, los continuos avances de las tecnologías de la información y la comunicación (TIC) han permitido reducir el tiempo (y aumentar la capacidad) de procesamiento de información, así como acelerar la comunicación entre máquinas, lo que se conoce como *latencia*. Una menor latencia posibilita explotar oportunidades de beneficio de duración cada vez más corta, incluso inferiores al segundo, que, si bien siempre han estado disponibles, no eran aprovechables a la velocidad de respuesta del ser humano. La única forma de explotarlas es mediante la automatización de las decisiones de negociación. La parte del AT que tiene por objeto explotar oportunidades de beneficio ultracortas generadas por el propio proceso de negociación a una velocidad extrema se conoce como negociación de alta frecuencia o *high frequency trading* (HFT). Las empresas especializadas en HFT (por ejemplo, Virtu, Hudson River, Jump Trading, Optiver, Tower Hill, etc.) desarrollan algoritmos para negociar exclusivamente por cuenta propia, es decir, con sus propios recursos. En general, podemos definir el HFT como negociación algorítmica en propiedad y de baja latencia.

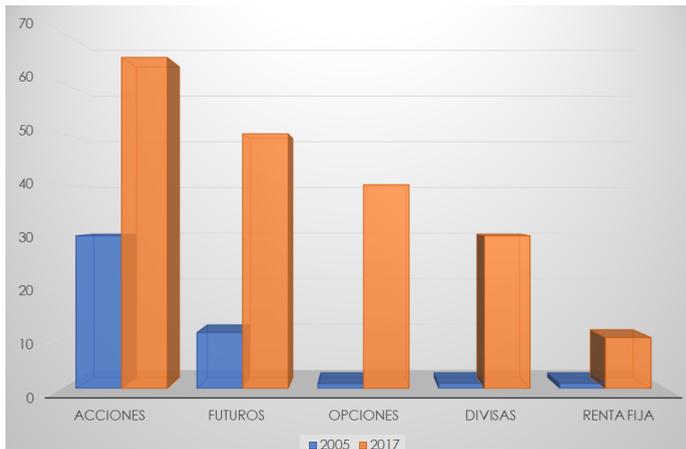
¿Cuán importante es el HFT? La [figura 3](#) muestra la evolución de la cuota de mercado del HFT en EE. UU. desde 2005 hasta 2022, medida en términos de porcentaje del volumen total negociado en dólares norteamericanos. En el año 2005 el HFT atesoraba ya el 20 % del mercado bursátil en EE. UU., mientras que era prácticamente inexistente en Europa. Impulsado por una volatilidad anormalmente elevada, cuatro años después, durante la crisis finan-

ciera de 2008-2009, el HFT alcanzaba su momento de mayor protagonismo, con cuotas del 61 % en EE. UU. y del 40 % en Europa. Más recientemente, la cuota del HFT se ha estabilizado alrededor del 50 % en EE. UU. y del 30-35 % en Europa.

Este rápido crecimiento ha dado lugar a un encendido debate entre reguladores (por ejemplo, SEC, 2014; ESMA, 2015) y medios especializados (por ejemplo, Duhigg, 2009; Bowley, 2010, 2011; Popper, 2012; Barlett y McCrary, 2015) sobre los pros y contras del HFT, espoleado por *bestsellers* mundiales (Lewis, 2014) que ofrecen una visión bastante sesgada y negativa sobre el HFT¹. El mundo académico no tardó en aceptar el desafío de proporcionar un marco teórico sólido y un trabajo empírico riguroso con el que poder abordar e intentar responder a las múltiples preguntas, dudas y preocupaciones que el HFT despertaba. Este trabajo resume los resultados y principales conclusiones de dicha investigación, desde los primeros estudios publicados, allá por el 2010, y hasta el momento en que se escriben estas líneas, a finales de 2022.

Figura 3.

Cuota del HFT en EE. UU. y Europa (% \$Vol)



Fuentes: TABB Group, Congressional Research Service (2016), IBISWorld (2022).

John Cochrane (2013), antiguo presidente de la American Finance Association, escribe que “desde un punto de vista social, la cuestión más relevante sobre el HFT es si arruina los mercados o los hace más eficientes y líquidos” (pág. 45). Este trabajo responde a la cuestión planteada por Cochrane: ¿Cuál ha sido el impacto del HFT en la *calidad* de los mercados financieros, entendida ésta como una función creciente de la liquidez y la eficiencia en precios? Los lectores familiarizados con la literatura sobre HFT echarán probablemente de

¹ Véase Kovac (2014) para una discusión crítica del libro de Lewis.

menos la mención de algún que otro trabajo. Es esperable, puesto que no pretende ser ésta una revisión exhaustiva. Los trabajos que se citan han sido seleccionados porque se consideran representativos y/o porque ilustran mejor las diferentes teorías y conclusiones que se desean exponer, sin poder (ni querer) evitar que las preferencias del autor se vean reflejadas en alguna que otra elección. Para el lector insatisfecho, hay otros muchos trabajos y libros excelentes con los que complementar este estudio².

2. NEGOCIACIÓN ALGORÍTMICA DE BAJA LATENCIA: UN MARCO GENERAL

2.1 ¿Qué caracteriza al HFT?

Hay que distinguir dos tipos de AT: en agencia y en propiedad. Los algoritmos en agencia son aquellos que intermediarios y desarrolladores de *software* ofrecen a sus clientes (fondos de inversión, fondos de cobertura) para minimizar los costes de ejecución, el tiempo de ejecución o el impacto en precios de su negociación. En este caso, la decisión de qué y cuánto comprar o vender no la toma el algoritmo, sino un gestor de carteras; el algoritmo ayuda a implementar dichas decisiones de la manera más eficiente posible. Puesto que el objetivo es ejecutar un cambio de posición, el AT en agencia mayormente demanda liquidez. Dado que los usuarios tienen horizontes de inversión a largo plazo, el éxito de sus estrategias no depende de la velocidad con la que el algoritmo implemente sus decisiones. Finalmente, el *input* de estos algoritmos es estimaciones históricas (impactos medios en precios, probabilidades de ejecución, etc.). No requieren de información en tiempo real más que para hacer seguimiento de sus propias órdenes³.

Por otro lado, los algoritmos en propiedad son desarrollados y utilizados por empresas tecnológicamente sofisticadas para negociar por cuenta propia. Las empresas especializadas en AT en propiedad se conocen como empresas de HFT. Algunos bancos e intermediarios financieros (por ejemplo, Goldman Sachs, JP Morgan, Citigroup), así como fondos de cobertura (por ejemplo, Citadel) tienen también mesas de negociación especializadas en HFT. El HFT explota oportunidades de beneficio cuyas duraciones se miden en unidades de tiempo inferiores al segundo, como milisegundos (ms), microsegundos (μ s) o nanosegundos (ns). Por tanto, un HFT debe ser capaz de responder a estímulos y señales del mercado a velocidades extremas y para ello tiene que poder acceder a la información que genera el mercado,

² Para revisiones de la literatura véase Biais y Woodley (2011); Foucault (2013); SEC (2014); Biais y Foucault (2014); Goldstein, Kumar y Graves (2014); O'Hara (2015) y Menkveld (2016). Para libros sobre AT/HFT véase Aldridge (2009); Johnson (2010); Patterson (2012); Narang (2013); Easley, López de Prado y O'Hara (2013) y Cartea, Penalva y Jaimungal (2015).

³ Para ejemplos específicos de algoritmos en agencia, véase Johnson (2010).

procesarla y mandar respuestas al mercado rápidamente⁴. Minimizar la latencia se convierte así en un elemento clave en el éxito de las estrategias de HFT. Para aumentar su velocidad, las empresas de HFT invierten en tecnología de vanguardia que utilizan para correr sus algoritmos. La intensa competencia con otras empresas de HFT les obliga a un reequipamiento continuo. Además, los negociadores de alta frecuencia (HFT) contratan servicios ofrecidos por el mercado que permiten incrementar la velocidad con la que sus servidores se comunican con el *host*. Veremos estos servicios de baja latencia en secciones posteriores.

Las empresas de HFT tienen un horizonte de *negociación*, no de *inversión*. Los HFT se preocupan poco por los fundamentos del valor de los activos que compran y venden, por las expectativas a largo plazo y por el riesgo de las empresas cuyos activos negocian. Esto se refleja en sus plazos entre constitución y liquidación de posiciones, que son extremadamente cortos. Los HFT evitan mantener grandes posiciones abiertas en cualquier activo. Para conseguirlo, negocian en cantidades pequeñas y gestionan intensivamente sus inventarios, manteniéndolos cercanos a cero durante y, especialmente, hacia el final de cada sesión.

Las estrategias de HFT generan un flujo de mensajes de negociación muy intenso. Esto es debido a que sus algoritmos monitorean el mercado en tiempo real, reaccionando a cualquier estímulo o señal valiosa, no sólo en busca de oportunidades de beneficio, sino también para gestionar el riesgo de las órdenes límite almacenadas en el libro. Los algoritmos responden a estas señales en forma de nuevas órdenes, revisiones y cancelaciones. Así, la actividad del HFT se caracteriza por unas ratios de mensajes sobre transacciones o cancelaciones sobre transacciones muy altas.

El HFT concentra su actividad, no en exclusiva, pero mayormente, en los activos más líquidos de cada mercado. Los activos líquidos garantizan inmediatez y, por tanto, velocidad en la ejecución de sus estrategias. La gestión de inventario se simplifica ya que los activos líquidos negocian con frecuencia y es más fácil revertir posiciones. Además, liquidez implica menores costes de negociación. Debido a la naturaleza de las oportunidades de beneficio que explotan los HFT, sus beneficios por operación son bajos, por lo que deben mantener bajos también sus costes de negociar. Por último, la negociación de los activos más líquidos se encuentra más fragmentada, repartida entre múltiples plataformas. La negociación fragmentada genera más oportunidades de beneficio que los HFT pueden explotar. En general, liquidez y facilidad de negociación son de enorme importancia para los HFT. Precisamente por ello, los HFT no participan en mercados OTC como, por ejemplo, el de bonos corporativos.

Por último, bajo la etiqueta HFT se incluyen un rango amplio de estrategias de negociación, que la literatura agrupa en dos grandes bloques: creación de mercado, esto es, provisión de liquidez, y negociación oportunista, que incluye, por ejemplo, arbitraje de baja

⁴ La naturaleza de estas señales es muy amplia, e incluye el flujo de órdenes y el estado del libro de órdenes (Kwan, Philip, y Shkilko, 2022), activos financieros correlacionados (Budish, Crampton y Shim, 2015) y anuncios públicos, tanto macroeconómicos como corporativos (Hu, Pan y Wang, 2017; Chordia, Green y Kottimukkalur, 2018). Pero podrían también extraerse de fuentes menos tradicionales, como mensajes de Twitter, opiniones en redes sociales, y mediante *news analytics* (Dugast y Foucault, 2018).

latencia y negociación direccional, que fundamentalmente implican toma de liquidez. Los HFT que se especializan en provisión de liquidez se conocen como *high-frequency market makers* (HFMM), mientras que los HFT que implementan estrategias oportunistas se conocen como *high-frequency bandits* (HFB) o *quote snypers*. Hablaremos de estas estrategias más adelante.

2.2. Un entorno favorable

La negociación algorítmica no es un fenómeno reciente. Ya en los años 80 del siglo XX los inversores institucionales hacían uso de algoritmos para rebalancear sus carteras o para negociar al precio medio ponderado (por volumen) de la sesión. El HFT, por contra, es un fenómeno del siglo XXI, facilitado en gran medida por la creciente automatización de los mercados, un entorno regulatorio favorable y la cada vez mayor fragmentación de los mercados financieros.

Piense en un mercado financiero. Seguramente, la imagen que tiene en mente es la de un parque (*trading floor*). ¿El del New York Stock Exchange (NYSE), tal vez? Un parque es un mercado físico, centralizado, en el que los operadores se encuentran para negociar, cara a cara. Sin embargo, en la actualidad las plataformas de negociación virtual han relegado estos parques a un papel secundario. En el NYSE, la negociación electrónica empezó en 1976, aunque limitada a órdenes pequeñas que demandaban ejecución inmediata y que eran gestionadas por el especialista en el parque⁵. En 1990 el parque todavía acaparaba el 70 % del volumen total negociado (Harris y Hasbrouck, 1996). Con los años, sin embargo, las capacidades del mercado electrónico fueron aumentando, de modo que a finales del siglo XX la cuota del mercado virtual era ya del 50 % (Sofianos y Werner, 2000). Tras la introducción de la ejecución automática para órdenes pequeñas contra el libro en 2000 y del *OpenBook* en 2002, que ofrecía por primera vez información sobre el libro de órdenes a operadores fuera del parque (Boehmer, Saar y Yu, 2005), la cuota del parque cayó en picado, situándose en un 20 % en 2006. Finalmente, con la implantación del sistema Hybrid a finales de 2006, que generalizó la ejecución automática de órdenes, la cuota del parque se situó en el 11 % (Hendershott y Moulton, 2011). En la actualidad, los operadores del parque trabajan mayormente órdenes de gran tamaño (bloques) y transacciones especialmente complejas. Como si de un piloto de avión se tratase, el parque interviene en el despegue (apertura), el aterrizaje (cierre) y en periodos de turbulencias (alta volatilidad); el resto del tiempo, el mercado funciona en piloto automático.

En un mercado electrónico, las órdenes se envían remotamente, mediante terminales de ordenador. El *host* se encarga después de emparejar las órdenes de signo opuesto según la regulación propia de cada mercado. En ningún momento hay contacto físico entre los participantes, ni se puede elegir a la contraparte. El mercado se organiza como un gran centro de

⁵ El CATS (*Computer Assisted Trading System*) de 1976 del Toronto Stock Exchange, fue el primer mercado 100 % virtual. El mercado español adoptó el CATS en 1989, y no fué hasta 1995 cuando se sustituyó por el Sistema de Interconexión Bursátil Español (SIBE). En el año 2002, el 67 % de los mercados bursátiles de todo el mundo eran ya totalmente electrónicos (Jain, 2005).

datos, un espacio físico para el almacenamiento del *host* y de los servidores de los operadores. Estos últimos se conectan al *host* mediante una compleja red de fibra óptica y/o inalámbrica. Siguiendo con nuestro ejemplo, el centro de datos del NYSE se encuentra en la ciudad de Mahwah, en el estado de New Jersey, a unos 14 kilómetros de Wall Street (Manhattan, Nueva York), donde el NYSE mantiene el parque.

La negociación se desarrolla alrededor de un libro de órdenes, electrónico y abierto, que constituye la única fuente de liquidez del mercado. Siguiendo un escrupuloso orden de llegada, el *host* valora la posibilidad de ejecutar inmediatamente cada orden con otra u otras de signo opuesto almacenadas en el libro. Si dos órdenes llegan simultáneamente, el *host* determina aleatoriamente el orden de prioridad. Si no existe contrapartida, la orden pasa a almacenarse en el libro, salvo instrucción explícita en contra, a la espera de ser ejecutada. La negociación es continua, desde la apertura al cierre. No obstante, muchos mercados siguen usando subastas (también electrónicas) para determinar el precio de apertura y/o cierre de la sesión y para reiniciar la sesión continua tras una interrupción, ya sea programada o forzada (*trading halt*) (por ejemplo, Abad y Pascual, 2010).

Los mercados virtuales tienen muchas ventajas sobre los mercados físicos. Ofrecen mayor capacidad para el procesamiento de órdenes, lo que redundará en un mayor volumen negociado. La velocidad con la que se procesan las órdenes es mayor, lo que permite ofrecer una respuesta más inmediata a las necesidades de los operadores. La cantidad de información que se puede procesar y transmitir en tiempo real es mayor, lo que se traduce en una mayor transparencia y eficiencia en precios. Los costes de operar en estas plataformas son menores, lo que conlleva menores comisiones y mayores ganancias por negociar. Además, las plataformas virtuales son más fáciles de supervisar, ya que toda la información se registra y almacena electrónicamente. Diversos estudios muestran efectos positivos de la automatización en la calidad de los mercados. Goldstein, Hu y Meng (2009) asocian negociación electrónica con menores costes de ejecución. Jain (2005) encuentra que cambiar de negociación física a virtual conlleva un menor coste de capital para las empresas cotizadas y una reacción positiva en el precio a corto plazo, consistente con un efecto positivo sobre la liquidez. Hendershott y Moulton (2011) encuentran que tras la entrada del *Hybrid* en el NYSE la eficiencia en precios mejoró.

Las ventajas de la negociación virtual sobre la física no pueden más que aumentar con el tiempo a raíz del continuo progreso en las TIC. Dado que las estrategias del HFT requieren de automatización y baja latencia, se benefician directamente de dicho progreso. La innovación en las TIC: (a) reduce la latencia, lo que permite aumentar la velocidad a la que los HFT pueden recibir, procesar y responder a señales del mercado, así como reducir el tiempo de ejecución de sus órdenes más agresivas; (b) aumenta el volumen de información que puede procesarse en un tiempo dado, reduciendo los costes de seguimiento de órdenes (*monitoring*) y posibilitando explotar oportunidades de arbitraje de ultracorta duración; (c) hace posible los servicios de baja latencia, como la colocación; y (d) atenúa las barreras de entrada⁶.

⁶ Por ejemplo, gracias al progreso tecnológico, operadores externos pueden competir con miembros del mercado en la provisión de liquidez. De hecho, estos *proveedores de liquidez endógenos (ELP)* han desplazado a los creadores de mercado tradicionales (Annand y Venkataraman, 2016). Muchos de ellos son empresas de HFT.

La automatización y la innovación tecnológica posibilitan las estrategias del HFT, pero no explican su eclosión. ¿Por qué se acelera el crecimiento del HFT en la primera década del siglo XXI? Las razones hay que encontrarlas, en primer lugar, en un cambio de marco regulatorio, tanto en EE. UU., con la Regulation New Market System (Reg NMS), como en Europa, con la Markets in Financial Instruments Directive (MiFID), ambas en vigor desde noviembre de 2007. Estas iniciativas regulatorias tenían como objetivo común reducir los costes explícitos (comisiones) e implícitos (iliquidez) de negociar, fomentando la innovación en la tecnología de negociación y la competencia. Para lograrlo, facilitaron la creación de plataformas de negociación alternativas (ATP/MTF) de propiedad y gestión privadas para casar órdenes fuera de los mercados tradicionales.

El principal resultado de la aparición de las ATP ha sido la creciente fragmentación de la negociación. El caso más llamativo es el de EE. UU. Solamente dos mercados determinan qué empresas se admiten a cotización (*listing exchanges*): el NYSE y el Nasdaq. Sin embargo, las acciones listadas en estos mercados se negocian, simultáneamente, en otras 22 ATP transparentes (*lit markets*), que tienen la categoría de National Securities Exchanges, además de en otros 69 mercados opacos (*dark pools*)⁷. Según el CFA Institute, en 2017 NYSE y Nasdaq tenían una cuota del 20 % sobre el volumen negociado de las acciones listadas en sus respectivos mercados. En general, los mercados transparentes (incluyendo NYSE y Nasdaq) representan el 60 % del volumen total negociado en EE. UU., otro 17 % es para las *dark pools*, y el resto corresponde a otros mecanismos de negociación (sistemas de internalización, OTC). En Europa, el grado de fragmentación es menor, no obstante, igualmente significativo. Según Fidessa⁸, en 2017 Bolsas y Mercados Españoles (BME) atesoraba una cuota del 47 % sobre el volumen total negociado en los activos del IBEX-35, similar a la del London Stock Exchange sobre los constituyentes del FTSE-100 o Euronext-Paris sobre las acciones del CAC-40.

La fragmentación y el HFT son fenómenos simbióticos. Por un lado, las nuevas plataformas de negociación necesitan ofrecer niveles de precios y de liquidez competitivos para poder atraer negociación y crecer (Menkveld, 2013). Por otro lado, los HFT necesitan de nuevas plataformas que satisfagan sus necesidades de automatización, velocidad y bajas comisiones. Además, los entornos fragmentados generan mayores oportunidades de beneficio para los HFT.

Un segundo factor importante para entender el *boom* del HFT es la crisis financiera mundial de 2008-2009, un entorno altamente volátil que aumentó los beneficios en juego para la industria del HFT y provocó la entrada de nuevos competidores. Este es el periodo en que el HFT alcanzó una mayor cuota de mercado en EE. UU. y Europa (ver *figura 3*). Tras la crisis financiera, la industria de HFT ha vivido un proceso de maduración y concentración. Por un

⁷ La literatura sobre fragmentación y *dark pools* es casi tan extensa como la literatura sobre HFT, y está fuera del alcance de este trabajo. Para el lector interesado, véase O'Hara y Ye (2011); Degryse, de Jong y van Kervel (2015); Comerton-Forde y Putnins (2015); Foley y Putnins (2016); Buti, Rindi y Werner (2017); Menkveld, Yueshen y Zhu (2017).

⁸ <https://fragmentation.fidessa.com/>

lado, los entornos estables no son favorables al HFT y, tras la crisis, los mercados tuvieron un crecimiento monótono. A los menores ingresos potenciales hay que añadir un aumento de los costes operativos (tecnología y servicios de baja latencia). En estas condiciones, los contendientes más pequeños fueron expulsados del mercado o absorbidos por las empresas más grandes, incrementando el nivel de concentración de la industria (Popper, 2012). Según IBISWorld⁹, en 2012 había 646 empresas de HFT operando en EE. UU. En 2017 quedaban 202 empresas y en 2022 únicamente 130. El crecimiento del volumen de negocio en el sector del HFT en EE. UU. entre 2017 y 2022, sin embargo, se estima en un 5,8 %, y el número de empleados se ha mantenido estable, alrededor de los 4.000.

2.3. Competencia en latencia

La velocidad es central en el éxito de las estrategias de HFT. Para ganar velocidad, los HFT hacen todo lo posible por minimizar su latencia. La latencia de un HFT i en un mercado j depende del tiempo que tarda el servidor del HFT i en recibir una señal del mercado j (por ejemplo, un cambio de precio); del tiempo que necesita el servidor del HFT i para procesar la señal y reaccionar a la misma (por ejemplo enviando un mensaje de cancelación de una orden en el libro); del tiempo que tarda esa respuesta en llegar al *host* del mercado j ; del tiempo que tarda éste último en procesar y ejecutar la cancelación; y, por último, del tiempo que tarda el HFT i en recibir algún tipo de respuesta del mercado j (p. ej., una confirmación de la cancelación). Es decir, la latencia del HFT i depende de su propia tecnología y poder computacional, pero también de la tecnología del mercado j y la velocidad de la red de comunicación entre el HFT i y el mercado j . Por tanto, el HFT i puede reducir su latencia invirtiendo en sistemas informáticos (*hardware* y *software*) ultrarrápidos que le permitan reducir el tiempo de procesamiento y reacción ante una señal informativa. Pero el mercado j también puede contribuir actualizando su propia tecnología para reducir el tiempo necesario para procesar instrucciones entrantes y salientes, así como emparejar órdenes y reportar transacciones.

Estas reducciones de latencia no dejan de ser un servicio que los mercados ofrecen a los operadores de forma gratuita, pero no por motivos altruistas. En un entorno fragmentado, como el descrito anteriormente, los mercados compiten entre sí para atraer flujo de órdenes, negociación. Al fin y al cabo, los mercados son organizaciones con ánimo de lucro, el volumen negociado es un determinante importante de su beneficio, y los HFT contribuyen significativamente al mismo, como ya hemos visto. No debería extrañar, por tanto, que los mercados mejoren su tecnología para acomodar sus plataformas a las necesidades del HFT.

El mercado j también contribuye a reducir la latencia del HFT i ofreciendo a éste servicios de baja latencia, esta vez sí, a cambio de una compensación. Uno de estos servicios es la *colocación*, evolución natural del concepto de proximidad. Los medios de comunicación

⁹ <https://www.ibisworld.com/united-states/market-research-reports/high-frequency-trading-industry/>

tienen corresponsales alrededor del mundo porque esperan que estar cerca de donde nace la noticia ayude a entender mejor lo que está sucediendo, así como procesar y reportar más rápido la información. Traslademos este símil a los mercados financieros: los operadores que estén más cerca del mercado deberían observar antes los movimientos de éste y sus respuestas procesarse antes. En otras palabras, a mayor proximidad, menor latencia.

Antes de la automatización, la ventaja de la proximidad correspondía a los operadores que estaban físicamente en el parqué, que podían observar lo que ocurría en el mercado antes de que se reflejase en las pantallas de los operadores conectados de forma remota. En la era del mercado virtual, pero antes de la eclosión del HFT, la proximidad se medía por la distancia geográfica entre la localización física del servidor del operador y la del *host*. Garvey y Wu (2010) muestran que aquellos operadores cuyo servidor está (geográficamente) más próximo al servidor del mercado no sólo ejecutan sus órdenes más rápidamente, sino que sus costes de ejecución son menores. La proximidad geográfica, por tanto, aumenta las ganancias de negociar. En la era del HFT, los operadores ubican sus servidores físicamente al lado del servidor del mercado, en centros de datos gestionados por éste, y conectados al *host* mediante redes de alta velocidad. Mientras que el HFT *i* que se abona al servicio de colocación del mercado *j* reduce su latencia unos pocos milisegundos, para el mercado *j* la colocación es una fuente de ingresos extra, ya que alquila el espacio físico (*rack space*) para el servidor del HFT *i* (por ejemplo, Bowley, 2011)¹⁰.

Brogaard *et al.* (2015) ilustran porqué la colocación es importante para el HFT. Analizan una mejora en el servicio de colocación del mercado bursátil sueco (NASDAQ-OMX Stockholm) en 2012. Las empresas que ya estaban suscritas al servicio de colocación tenían la posibilidad de reducir su latencia un 20 % cambiando a un servicio de colocación más rápido, llamado FastColo, a cambio de pagar una cuota más alta. Las empresas que aceptaron la actualización fueron los HFT especializados en crear mercado. El estudio concluye que éstas vieron potenciadas sus habilidades como proveedores de liquidez (*vis-à-vis* otras empresas que no actualizaron). En particular, redujeron sus costes de proveer liquidez y, como resultado, aumentaron su competitividad. Además, trasladaron sus menores costes a sus clientes en forma de menores primas y descuentos por negociar. También aportan evidencia de efectos positivos de la colocación sobre la calidad del mercado, un resultado apoyado por otros estudios y otros mercados (Boehmer, Fong y Wu, 2020; Frino, Mollica y Webb, 2014), incluyendo el español (Chakrabarty *et al.*, 2017).

Un segundo servicio de baja latencia es el acceso directo a fuentes de datos. La venta de datos es una importante fuente de ingresos para las bolsas. En EE. UU., por ejemplo, las diferentes plataformas de negociación deben comunicar en tiempo real sus mejores cotizaciones y sus transacciones a los *listing exchanges*, NYSE y Nasdaq. Sus *Security Information Processors* (SIP) utilizan esta información para generar las cotizaciones consolidadas, conocidas como *Net Best Bid and Offer* (NBBO). Esta información se almacena en la llamada *Consolidated*

¹⁰ En España el servicio de colocación existe desde noviembre de 2012 (Chakrabarty, Moulton y Pascual, 2017).

*Tape*¹¹. La Consolidated Tape Association, que pertenece a los propios mercados, vende la información a los *vendors* (Thomson Reuters, Bloomberg, etc.), quienes a su vez la venden a los operadores. La participación de cada bolsa en los ingresos de la venta de datos depende de su contribución al volumen de datos. Las bolsas han encontrado una forma de complementar estos ingresos mediante la venta directa de datos a sus clientes. Por ejemplo, el NYSE ofrece diferentes productos de venta directa, como NYSE Best Quote y NYSE Open Book, al tiempo que el Nasdaq hace lo propio bajo el nombre de Nasdaq ITCH. Si el HFT *i* contrata el acceso directo a los datos del mercado *j*, verá esencialmente la misma información que aquellos que siguen el canal estándar, pero unos pocos milisegundos antes, y pagará más por ello¹².

Diferencias en la velocidad de acceso a la información pueden resultar en un mayor riesgo para los proveedores de liquidez. En EE. UU., los HFT con acceso directo a las fuentes de datos observan cambios en el NBBO unos pocos milisegundos antes que los proveedores de liquidez con acceso al NBBO del SIP. Por tanto, los primeros podrían arbitrar con esta ventaja para beneficiarse a costa de los segundos. Ding, Hanna y Hendershott (2014) encuentran frecuentes distorsiones entre el NBBO calculado a partir de las fuentes directas de datos y el NBBO del SIP, pero éstas duran 1,5 ms en media y abarcan apenas un 1 % de la duración total de una sesión. Bartlett y McCrary (2019) estiman que los beneficios brutos potenciales por año para el HFT en estrategias de arbitraje basadas en dichas distorsiones serían de unos 156-214 millones de dólares anuales para todo el mercado. Comparados con los beneficios anuales de una sola empresa de HFT (por ejemplo, Virtu Financial generó 700 millones de dólares en 2016) parece una cifra más bien pequeña. Esto sugiere que el HFT paga por este servicio para apoyar otro tipo de estrategias, como la creación de mercado. Hasbrouck (2021) estima que, con una periodicidad de 1 segundo, las cotizaciones del SIP y del flujo directo de datos son igualmente informativas. Sin embargo, con periodicidades de 100 μ s o menos, las cotizaciones del flujo directo reflejan la nueva información antes de forma sistemática. Por tanto, los HFT que se subscriben a este servicio de baja latencia deberían tener cotizaciones más informativas y estar expuestos a un menor riesgo de selección adversa (Hoffmann, 2014; Hendershott y Riordan, 2013).

Por último, el HFT *i* también puede reducir su latencia contratando los servicios de conectividad de alta velocidad que ofrece el mercado *j*. En las últimas décadas, se han emprendido proyectos a gran escala dirigidos a reducir la latencia en la comunicación entre mercados geográficamente distantes. Estos proyectos consisten en la instalación de redes de microondas de alta velocidad o en el tendido de cables de fibra óptica, incluso submarinos, para transferir datos a gran velocidad entre plataformas. Un ejemplo representativo es el de *Spread Networks of Ridgeland* (Laughlin, Aguirre y Grundfest, 2014; Lewis, 2014)¹³. Se trata

¹¹ En Europa no existe un registro consolidado similar, pero su creación es parte de los objetivos del 2020 *Capital Markets Union (CMU) Action Plan*, véase <https://finance.ec.europa.eu/capital-markets-union-and-financial-markets/capital-markets-union>

¹² En el Nasdaq, el coste de un servidor colocado que utiliza datos SIP es de unos 7.000 dólares al mes; si utiliza acceso directo a los datos del mercado el coste se triplica.

¹³ Otros ejemplos serían EXA-Express y Perseus Telecom.

de un cableado de fibra óptica de más de 1.300 km. que conecta el centro de datos del Chicago Mercantil Exchange (CME) con el del NYSE en New Jersey, que redujo la latencia existente en unos 3 ms (de 16 a 13 ms). Si bien ya existía un cableado similar desde la década de los años 80, éste estaba colocado a lo largo de las vías de tren existentes, con lo que su trazado distaba en unos 322 km. de la distancia en línea recta entre ambos mercados. La empresa tecnológica Spread Networks reparó en la potencial reducción de latencia de una configuración más lineal y en 2010 completó el tendido del nuevo cableado. Las empresas de HFT se pasaron al nuevo cableado, a pesar de ser sensiblemente más caro. Dos años después, sin embargo, el cable original de Spread Networks quedó obsoleto. Las redes de microondas aparecieron como un método más rápido de transmitir la información y sin la necesidad de excavar túneles. Estas nuevas redes redujeron inicialmente la latencia de ida y vuelta entre ambos mercados a 10 ms, y más recientemente a 8 ms.

En la actualidad, los operadores que negocian entre Chicago (derivados) y Nueva York (contado) pueden elegir entre cableado de fibra óptica o red de transmisión por microondas para recibir y enviar información. Si bien las redes de microondas son más rápidas, también son más inestables, ya que se puede interrumpir la comunicación. Episodios de mal tiempo, como intensas lluvias o fuertes nevadas, están entre las causas de dichas alteraciones. Shkillo y Sokolov (2020) estudian caídas en la red de microondas entre Chicago y Nueva York entre 2011 y 2012 debidas al mal tiempo. Durante ese periodo, la red de microondas era accesible solo a un número limitado de empresas de HFT, creando una jerarquía en el mercado en términos de velocidad. Esas empresas de HFT más rápidas se dedicaban, principalmente, al arbitraje de baja latencia. Shkillo y Sokolov encuentran que, durante episodios de mal tiempo, la velocidad de reacción de Nueva York a señales procedentes de Chicago aumenta de media en 2 ms, precisamente la diferencia de velocidad entre la fibra óptica y la red de microondas¹⁴. Además, los HFT conectados a la red de microondas paran sus algoritmos, ya sea por una disminución en la probabilidad de éxito de sus estrategias de arbitraje o porque se vuelven económicamente inviables.

Quizá el lector se pregunte hasta qué punto diferencias de latencia del orden de unos pocos milisegundos entre las empresas de HFT se pueden traducir en diferencias significativas en términos de competitividad, rentabilidad y cuota de mercado¹⁵. Esta es la pregunta que un estudio realizado por Baron, Brogaard, Hagströmer y Kirilenko (2019) intenta responder. Utilizando datos del Nasdaq OMX, analizan la competencia en latencia entre las empresas de HFT y sus implicaciones para la estructura de la industria. Sus resultados muestran que los HFT más rápidos generan mayores ingresos por negociar, porque son capaces de capturar un mayor número de oportunidades de beneficio. Como consecuencia, las empresas más rápidas acaparan también gran parte del volumen negociado por la industria del HFT.

¹⁴ Según los autores, la luz cubre la distancia de Chicago a Nueva York en unos 4 ms, la señal de microondas tarda 4,5 ms y la de fibra óptica 6,5 ms.

¹⁵ Por tener una referencia con que comparar, el ser humano requiere en media de 100 ms para parpadear, y unos 180-200 ms para responder a un estímulo visual – véase <https://bionumbers.hms.harvard.edu>

3. EL MÉTODO CIENTÍFICO Y LA IDENTIFICACIÓN DEL HFT

¿Cómo se mide empíricamente la actividad del HFT? Cualquier académico interesado en el HFT desearía poder aislar las órdenes y transacciones de estos operadores de las del resto del mercado. Algunos lo consiguen mediante el uso de bases de datos no públicas que identifican la actividad del HFT, ya sea como industria global (por ejemplo, Brogaard, Hendershott y Riordan, 2014, 2019; Kirilenko, Kyle, Samadi y Tuzun, 2017) o por empresa (por ejemplo, Baron, Brogaard, Hagströmer y Kirilenko, 2019; Boehmer, Li y Saar, 2018). Como la gran mayoría de académicos no tiene acceso a estas bases de datos, los anteriores estudios no son replicables, siendo la replicabilidad un aspecto fundamental en la investigación científica. Además, algunas de estas bases de datos (por ejemplo, Nasdaq HFT-data, EUROFIDAI, IIROC) identifican a los HFT mediante medidas indirectas (*proxies*). Estas bases son pues tan fiables como fiables sean las *proxies* utilizadas. Finalmente, cuando los identificadores de HFT son agregados, como suele ser el caso, toda inferencia se hace sobre un HFT genérico mientras que el HFT engloba un conjunto muy heterogéneo de estrategias.

Las bases de datos de alta frecuencia de más fácil acceso (NYSE TAQ, Refinitive's Tick History Data) no proporcionan identificadores de HFT¹⁶. Algunos estudios recurren a *shocks* exógenos que afectan a la latencia del sistema de negociación como instrumentos para identificar cambios en la actividad del HFT. Intuitivamente, cambios en la actividad agregada del mercado dentro de ventanas de latencia ultracortas como respuesta a un *shock* exógeno deben ser atribuibles mayormente al HFT. Ejemplos de *shocks* exógenos serían una mejora en la tecnología de negociación (Conrad, Wahal y Xiang, 2015), la introducción o mejora en los servicios de colocación (Boehmer, Fong y Wu, 2021), restricciones o suspensiones en la conectividad (Chakrabarty, Jain, Shkilko y Sokolov, 2021), caídas en las redes de comunicación (Shkilko y Sokolov, 2020) o límites intencionados a la latencia (Chakrabarty, Huang y Jain, 2022). La principal limitación de estos estudios es que se basan en eventos (*shocks*) singulares, con lo que la atribución de los resultados al HFT es cuanto menos complicada.

Finalmente, muchos estudios académicos utilizan medidas indirectas para inferir sobre la actividad de los HFT. Estas *proxies* pretenden capturar características en los datos que es más probable que puedan atribuirse a la negociación algorítmica que a la no algorítmica. Hendershott, Jones y Menkveld (2011), por ejemplo, sugieren utilizar el flujo de mensajes de negociación durante un periodo dado (escalado por el volumen negociado) como *proxy* de AT, basándose en la noción de que el HFT es el principal contribuidor a dicho flujo. Un componente importante del flujo de mensajes son las cancelaciones de órdenes. Desde el año 2000, las ratios de cancelaciones sobre transacciones ejecutadas han crecido dramáticamente (Angel, Harris y Spatt, 2015). Este crecimiento es atribuible, en gran medida, a la irrupción del HFT y a la creciente fragmentación del mercado (Khomyn y Putnins, 2021). De hecho, muchos trabajos empíricos reportan tasas de cancelaciones mucho más altas para los HFT

¹⁶ Por datos de alta frecuencia se entiende datos de eventos discretos ordenados en tiempo continuo, sin agregar, como transacciones o cotizaciones.

que para otros operadores (por ejemplo, Friederick y Payne, 2015; Jørgensen, Skjeltorp y Ødegaard, 2018; Malinova, Park y Riordan, 2018).

El **cuadro 1** muestra valores medios de medidas indirectas de HFT calculadas con una periodicidad de 60 segundos para las 50 empresas más negociadas en el National Stock Exchange of India (NSE) en 2015. Las diferentes medidas se calculan con el flujo de órdenes de tres tipos de operadores: los HFT, otra negociación algorítmica (AT en agencia) y negociación no algorítmica (NAT). Puede observarse cómo los HFT introducen un mayor número de mensajes de negociación, así como también cancelaciones y revisiones de órdenes límite, por minuto que los demás agentes. Las diferencias son especialmente notables cuando comparamos con los operadores no algorítmicos.

Algunas voces consideran las elevadas tasas de cancelaciones de órdenes excesivas, el síntoma de una disfuncionalidad (SEC, 2010), incluso el reflejo de posibles prácticas fraudulentas (*quote stuffing*, *spoofing*, etc.) por parte del HFT (Eggington, Van Ness y Van Ness, 2016). Sin embargo, la literatura existente, como veremos, sugiere que éstas pueden generarse de forma natural por actividad de los HFMM que no es ni ilícita ni dañina como, por ejemplo, respuestas ultrarrápidas a señales informativas generadas por el mercado (Brolley y Malinova, 2021; Kwan, Philip y Shkilko, 2022), gestión del riesgo de selección adversa (Jovanovic y Menkveld, 2016; Bhattacharya y Saar, 2021) y competencia para obtener prioridad de ejecución (Hasbrouck, 2018). Además, los HFMM replican sus posiciones en múltiplos.

Cuadro 1.

Medidas indirectas de actividad del HFT

Proxy	HFT	Otro AT		NAT	
Mensajes	654,08	204,12	***	55,76	***
Cancelaciones y revisiones	293,18	61,62	***	6,87	***
Órdenes fugaces	82,24	26,89	***	6,46	***
<i>Quote flickering</i>	137,91	88,84	***	36,72	***
Respuestas ultrarrápidas	38,27	11,93	***	0,55	***
Carreras estratégicas	10,49	0,51	***	0,02	***

Este cuadro proporciona valores medios de medidas indirectas (*proxies*) de actividad del HFT, calculadas sobre intervalos regulares de 60 segundos. Promediamos los valores, primero, por activo y, después, en sección cruzada. Utilizamos datos de los constituyentes del NYFTY-50, índice representativo del National Stock Exchange of India (NSE), durante el periodo mayo-julio de 2015. Distinguimos tres tipos de operadores: HFT, otros AT, y negociación no algorítmica (NAT). Las *proxies* son: (1) el número de mensajes de negociación introducidos relativamente cerca (<10 ticks) de las mejores cotizaciones; (2) el número de cancelaciones o revisiones de órdenes limitadas, siempre que éstas órdenes se encuentren relativamente cerca de las mejores cotizaciones; (3) el número de órdenes fugaces, esto es, canceladas menos de 100 ms después de haberse introducido; (4) *quote flickering*, medido como el número de cambios en las mejores cotizaciones; (5) el número de primeras respuestas a cambios en las mejores cotizaciones que se producen en menos de 100 ms; (6) el número de carreras estratégicas (Hasbrouck y Saar, 2013) con una longitud mínima de 10 mensajes ligados. *** indica diferente al valor para el HFT al 1% de significatividad estadística.

tiples plataformas a la vez (Menkveld, 2013; van Kervel, 2015), por lo que cualquier decisión de cancelación/revisión en un mercado puede implicar cambios simultáneos de órdenes en múltiples mercados.

Al examinar el libro de órdenes de Island, una plataforma de negociación electrónica posteriormente incorporada al Nasdaq, Hasbrouck y Saar (2009) encuentran que alrededor del 25 % de las órdenes límite introducidas son canceladas en menos de dos segundos. Llamaron a estas órdenes “fugaces” (*fleeting*). Aunque no asocian las órdenes fugaces al HFT directamente, sí las ligan al progreso tecnológico. Con el tiempo, el uso de órdenes fugaces no ha hecho más que aumentar. Según la SEC (SEC, 2014), en EE. UU. el 90 % de las órdenes límite se cancelan dentro del segundo posterior a su entrada en el sistema. El **cuadro 1** muestra cómo el uso de órdenes fugaces (en este caso, órdenes canceladas o revisadas en menos de 100 ms) no es exclusivo del HFT, pero sí son sus usuarios más activos. Así, la frecuencia en el uso de órdenes fugaces es una medida indirecta de la actividad del HFT (Cartea *et al.*, 2019).

Hasbrouck y Saar (2013) sugieren capturar estrategias dinámicas de baja latencia basadas en órdenes limitadas, atribuibles a los algoritmos del HFT, mediante lo que ellos denominan “carrera estratégica” (*Strategic Run*), en adelante *SRun*. Una *SRun* empieza con la entrada en el sistema de una orden límite que es cancelada sin ser ejecutada. Dicha cancelación se liga con una nueva orden de igual signo (compra o venta) y tamaño, siempre y cuando ésta última haya entrado en el sistema menos de 100 ms después. La *SRun* sigue adelante ligando cancelaciones y nuevas órdenes, y termina cuando la última orden ligada es ejecutada o cancelada y no hay posibilidad de ligarla a una nueva orden. Esta medida ha sido utilizada en diversos estudios empíricos (por ejemplo, Bartlett y McCrary, 2019; Chordia y Miao, 2020). En el **cuadro 1** podemos observar que los HFT del NSE generan la gran mayoría de las *SRuns*.

Otra característica diferenciadora del HFT es su capacidad de responder rápidamente a cualquier señal procedente del mercado, por ejemplo, cambios en el libro (Kwan *et al.*, 2022), o cambios en otros mercados, por ejemplo, derivados (Brogaard, Hendershott y Riordan, 2014). Cabe esperar que mayor competencia entre empresas de HFT se traduzca en mayor velocidad de respuesta a cualquier señal informativa. Así, diferentes estudios utilizan la velocidad de respuesta como medida indirecta de HFT (por ejemplo, Chakrabarty, Jain, Shkilko y Sokolov, 2021). El **cuadro 1** muestra que los HFT del NSE son los más rápidos en responder a cambios en las mejores cotizaciones del mercado.

Para poder construir las *proxies* de HFT anteriores se requiere de información detallada sobre el flujo de órdenes, orden por orden. Las bases de datos públicas no suelen proporcionar dicho nivel de detalle. No obstante, encontramos en la literatura medidas que pueden calcularse a partir de información disponible, por ejemplo, en la NYSE-TAQ. Estas *proxies* miden un fenómeno conocido como *quote flickering*, esto es, cambios rápidos y frecuentes en las mejores cotizaciones del mercado, cuya creciente intensidad se atribuye al HFT. Conrad, Wahal y Xiang (2015) miden la intensidad del HFT a través del *high-frequency quoting* (HFQ), que no es más que el número de cambios en las mejores cotizaciones en un intervalo de

tiempo, ya sea por variaciones del mejor precio de compra (*bid*) o venta (*ask*) o por variaciones en el volumen (profundidad) ofrecido a dichos precios. El **cuadro 1** muestra cómo el HFQ es mayor para los HFT que para el resto de los operadores. Como alternativa, Hasbrouck (2018) mide *quote flickering* como la desviación típica de las cotizaciones (en niveles) en horizontes de unos pocos milisegundos.

Chakrabarty, Comerton-Forde y Pascual (2022) estudian la fiabilidad y precisión de las medidas indirectas de HFT. Encuentran que todas estas medidas están altamente correlacionadas entre sí y que señalizan correctamente variaciones en la actividad real de los HFT. No obstante, algunas medidas destacan por encima de las demás. *SRun* de Hasbrouck y Saar (2013) es la medida que mejor aísla la actividad del HFT de la actividad de otros tipos de operadores. Las medidas basadas en la velocidad de respuesta son más efectivas a la hora de identificar periodos/activos con mayor contribución del HFT a la provisión de liquidez. Asimismo, una mayor presencia de órdenes límite con la condición especial *immediate-or-cancel* (*IOC*) destaca a la hora de identificar periodos/activos con una mayor contribución del HFT a la demanda de liquidez.

4. LA DIVERSIDAD DEL HFT

¿Qué hacen exactamente los HFT? ¿Qué tipo de estrategias implementan? Los algoritmos de las empresas de HFT no son públicos. Por tanto, los académicos tienen que inferir, a partir de los datos disponibles, cuáles son las estrategias más comunes entre las empresas de HFT. Un ejemplo ilustrativo es el trabajo de Boehmer, Li y Saar (2018). Estos autores estudian la diferenciación de producto y la competencia en el sector del HFT, donde *producto* significa estrategia de negociación. Según la teoría de la organización industrial, cuanto más similares son los productos de las empresas de un sector, más competitivo es el entorno. Esta idea es también aplicable al caso del HFT: dos empresas de HFT que apliquen la misma estrategia responderán a los mismos estímulos y buscarán explotar las mismas oportunidades de beneficio. Por tanto, cuanto más similares sean las estrategias de las empresas de HFT, más competitivo será el sector.

Boehmer *et al.* (2018) disponen del tráfico de mensajes de las empresas de HFT en el Toronto Stock Exchange, que refleja el resultado de la actividad de los algoritmos que cada empresa utiliza para implementar sus estrategias. Se espera que cada estrategia cree un perfil único de mensajes, que deje huellas propias en los datos. Si esa estrategia es común a muchas empresas de HFT, esas huellas se repetirán en los mensajes de todas ellas, generando patrones comunes. Utilizando técnicas estadísticas, identifican tres productos diferenciados que explican el 96 % de los mensajes y el 79 % del volumen negociado del HFT que, por orden de relevancia, serían: creación de mercado (*i.e.*, provisión de liquidez), arbitraje y especulación direccional. Las dos últimas se engloban en lo que se conoce como *negociación oportunista*.

El estudio de Boehmer *et al.* (2018) revela, en primer lugar, una clara heterogeneidad de productos en el sector. Además, muestra que se trata de una industria altamente competitiva,

ya que las empresas de HFT tienen productos muy similares. Por último, si bien otras estrategias son posibles, no serían representativas de lo que hace el HFT¹⁷.

4.1. Creación de mercado

Muchos HFT son creadores de mercado (CM), esto es, operadores especializados en el negocio de proporcionar liquidez. Un CM proporciona liquidez voluntariamente. Para ello, publica precios a los que está dispuesto a comprar (*bid*) y vender (*ask*) un número limitado de títulos del correspondiente activo, de tal forma que el $ask > bid$. El CM genera un beneficio al realizar el diferencial *ask-bid* muchas veces a lo largo de la sesión y para múltiples activos. Este diferencial se conoce como horquilla o *spread*, y puede entenderse como la suma de una prima (sobre el valor de consenso) que el CM demanda a cualquier tomador que desee comprar el activo y un descuento que el CM solicita a cualquier tomador que desee vender el activo. Estas primas y descuentos aumentan con el riesgo y los costes que soporta el CM (O'Hara, 1995).

Para establecer su *spread*, el CM introduce órdenes que no demandan ejecución inmediata, especificando el precio límite al que está dispuesto a comprar y vender, así como la cantidad máxima que se ofrece a negociar. Ese tipo de orden se llama *límite*. Una orden límite demanda ejecución al mejor precio disponible, siempre que dicho precio no sea peor que el precio límite especificado. Por ejemplo, la orden “comprar 100 acciones de TEF a €3,35” indica que el operador está dispuesto a comprar 100 acciones de Telefónica siempre y cuando el precio sea igual o inferior a 3,35 euros/acción. Para que esta orden se ejecute automáticamente debería haber en el mercado otro operador que hubiera manifestado antes su interés de vender a 3,35 euros o menos. Si tal contrapartida no existe, la orden se almacena en el libro de órdenes a un precio *bid* de 3,35 euros. En ese instante se convierte en fuente de liquidez.

El uso de órdenes límite implica riesgos o costes que son inherentes a la actividad del CM. Supongamos que nuestro CM tiene su orden de TEF almacenada en el libro cuando llegan al mercado malas noticias que empujan el precio de consenso de TEF por debajo de 3,35 euros. En ese instante, la orden del CM está *en dinero* al ser una opción de venta a un precio por encima del valor de consenso. Si el CM no cancela su orden rápidamente se expone al riesgo de que otro operador la tome y se ejecute en pérdidas. En un escenario alternativo, pero de consecuencias similares, la orden del CM es tomada por un operador con acceso a información privada que, de hacerse pública, movería el valor de consenso por debajo de los 3,35 euros. Si el CM no deshace su recién adquirida posición (*i.e.*, vende las acciones de TEF) antes de que eso ocurra, incurriría en una pérdida. El riesgo de que una orden límite se ejecute en dinero se conoce como *riesgo de selección adversa*, y los costes asociados se conocen como *costes de selección adversa*. Un mayor riesgo de asimetrías de información aumenta el riesgo de selección adversa y, por tanto, las horquillas demandadas por los CM.

¹⁷ Por ejemplo, el HFT ha sido acusado de incurrir en prácticas manipulativas (véase Egginton *et al.*, 2016).

El ejemplo anterior ilustra que una orden límite almacenada en el libro es una opción de compra (CALL) o venta (PUT) que el CM ofrece al resto del mercado. Como tal, toda orden límite tiene valor, creciente con la probabilidad de que pueda entrar en dinero en algún momento. Mayor valor como opción implica mayor riesgo de selección adversa. De la teoría sobre opciones financieras (por ejemplo, Hull, 2021) sabemos que el valor de un contrato de opción aumenta con factores como la volatilidad del subyacente o el precio de ejercicio (*strike*). Igualmente, el valor de una orden límite aumenta con la volatilidad del activo debida a nueva información. El *strike* de una orden límite es el precio límite especificado. Cuanto más agresivo sea el CM a la hora de fijar el *strike* (i.e., más cerca del mejor *ask* o del mejor *bid* del libro), mayor su riesgo. Cuando una opción se puede ejercer en cualquier momento (*americana*), su valor aumenta con el tiempo que esté disponible. De forma similar, mantener una orden límite mucho tiempo en el libro aumenta el riesgo de que se ejecute en dinero. Finalmente, el beneficio potencial del tomador que ejecuta una orden límite en dinero aumenta con su tamaño. Por tanto, órdenes grandes tienen mayor valor y acarrear un riesgo más alto.

Un CM puede gestionar los riesgos ligados a la llegada de nueva información reduciendo el valor de sus órdenes límite. Para ello, puede usar órdenes poco agresivas, de pequeño tamaño, evitar los picos de volatilidad, y dejarlas en el libro por periodos cortos de tiempo. No obstante, esta estrategia pasiva podría dañar significativamente sus beneficios al aumentar la probabilidad de no ejecución y reducir su competitividad.

Los operadores profesionales gestionan el riesgo de sus órdenes límite realizando una intensa actividad de seguimiento y evaluación del flujo continuo de información que emana del (o llega al) mercado, revisando y cancelando sus órdenes en el libro cuando perciben una mayor exposición. Esta actividad se conoce como supervisión (*monitoring*). Altas tasas de cancelaciones y revisiones de órdenes pueden sugerir, por tanto, gestión activa del riesgo por parte de los CM (por ejemplo, Liu, 2009). El seguimiento de órdenes tiene un coste, en forma de tiempo y recursos destinados a la misma. En consecuencia, el CM se enfrenta a un tira y afloja entre costes de seguimiento y riesgo. Si los costes de seguimiento son bajos, el CM supervisará activamente sus órdenes; si son altos, es más probable que opte por una estrategia de gestión del riesgo pasiva, asumiendo un mayor riesgo de no negociar. Los HFT confían en algoritmos para realizar la actividad de supervisión de órdenes, por lo que sus costes de supervisión son relativamente bajos. No es sorprendente, pues, que los HFT sean los operadores que más contribuyen al número total de revisiones y cancelaciones de órdenes en los mercados actuales (por ejemplo, Khomyn y Putnins, 2021; Abad *et al.*, 2022).

La teoría existente (por ejemplo, Hoffmann, 2014; Bogaerts y Van Achter, 2021) predice que la combinación de alta velocidad de reacción e intensiva supervisión de órdenes permite a los HFT gestionar el riesgo de selección adversa mejor que otros CM. La evidencia empírica apoya esta predicción. Por ejemplo, Hendershott y Riordan (2013) encuentran que los HFT que operan en el Deutsche Börse Xetra son más propensos a cancelar órdenes límite (reacción) que están en dirección opuesta a cambios recientes en precios del mercado de futuros (señal informativa). Asimismo, Subrahmanyam y Zheng (2014) encuentran que los HFT del Nasdaq cancelan órdenes en anticipación a movimientos opuestos del precio a corto plazo.

Estos estudios sugieren que es menos probable que las órdenes límite de los HFT se ejecuten en dinero que las de otros CM. En este sentido, Brogaard *et al.* (2015) muestran que las empresas de HFT que contrataron el servicio FastColo del Nasdaq OMX experimentaron una reducción significativa en su riesgo de selección adversa vis-à-vis empresas que no lo hicieron. Podemos concluir, por tanto, que los HFT gozan de una exposición al riesgo de selección adversa menor que otros proveedores de liquidez.

Junto con la supervisión de órdenes, un CM puede reducir el valor de sus órdenes límite utilizando órdenes de volumen oculto (por ejemplo, Bessembinder, Panayides y Venkataraman, 2009; Pardo y Pascual, 2012). Éstas permiten ocultar, total o parcialmente, el tamaño de órdenes límite en mercados que, por lo demás, son transparentes. Intuitivamente, al ocultar la orden el CM reduce su valor como opción. Chakrabarty, Hendershott, Nawn y Pascual (2022) muestran que los HFT usan órdenes de volumen oculto, si bien en menor grado que otros operadores.

Cuando los tomadores de liquidez que compran y los que venden no llegan al mercado con la misma intensidad se producen desequilibrios en el flujo de órdenes, que deben ser absorbidos por los CM. Como resultado, los CM se ven forzados a mantener posiciones abiertas probablemente no deseadas en dichos activos durante cierto tiempo. Si la posición es larga, el CM se expone al riesgo de una caída de precios; si es corta, el CM se expone al riesgo de una subida de precios. Es decir, el CM está expuesto a fluctuaciones adversas de los precios, y este riesgo persiste hasta que revierte su inventario. Si nuestro CM es averso al riesgo, trasladará este riesgo de gestión de inventario a sus clientes en forma de mayores *spreads* (Ho y Stoll, 1983).

La teoría y la evidencia empírica existentes confirman que el HFT explota su mayor velocidad, la supervisión intensiva de órdenes y la fragmentación del mercado para gestionar mejor su riesgo de inventario. Por ejemplo, Ait-Sahalia y Saglam (2017) desarrollan un modelo teórico en el que los HFT interpretan mejor las señales del mercado, lo que mejora su capacidad para predecir la dirección del flujo de órdenes entrante. Poder anticipar mejor los desequilibrios entre órdenes de compra y venta a corto plazo les permite gestionar mejor su riesgo de inventario, lo que se traduce en cotizaciones más agresivas (*spreads* más estrechos) y en poder soportar rangos de inventario más amplios. Hirschey (2021) aporta apoyo empírico a la premisa del modelo al mostrar que, de hecho, los HFT pueden anticipar la dirección del flujo de órdenes de otros operadores. Los HFT pueden utilizar su capacidad de anticipación para actualizar de forma óptima sus cotizaciones y así gestionar mejor su riesgo de inventario. Por otro lado, Brogaard *et al.* (2015) muestran que los HFMM que suscribieron el servicio FastColo del Nasdaq OMX redujeron la frecuencia de reversión de su inventario a cero, lo que sugiere una menor exposición al riesgo de inventario, al tiempo que aumentaron su presencia en las mejores cotizaciones, lo que refleja horquillas más estrechas debido a sus menores costes de inventario.

En un entorno de negociación fragmentado pueden producirse desajustes en el espacio entre compradores y vendedores de un mismo valor. Por ejemplo, un inversor institucional envía una gran orden de compra de TEF a la Bolsa de Madrid, mientras otro introduce una

gran orden de venta de TEF en el mercado alternativo Cboe. Un HFMM que opere en ambas plataformas puede, por ejemplo, ofrecerse a comprar TEF en Cboe a, digamos, 3,3 euros la acción, para inmediatamente después revender los títulos en Bolsa de Madrid a 3,31 euros. Este ejemplo ilustra que la capacidad de negociar rápidamente entre plataformas permite al CM reducir el tiempo durante el cual su inventario está en riesgo. Menkveld (2013) aporta evidencia empírica de esta estrategia multiplataforma.

Además de mejorar sus habilidades de gestión de riesgos, la teoría (Foucault, Kadan y Kandel, 2013) sugiere que los HFT aprovechan su mayor velocidad e intensidad de supervisión para explotar oportunidades de obtener beneficios anormales en la provisión de liquidez. En el ejemplo de las acciones de TEF, suponga que una orden de venta agresiva de gran tamaño toma toda la liquidez disponible a las mejores cotizaciones *bid* del libro de TEF en Cboe. Como resultado, el diferencial entre el mejor *ask* y el mejor *bid* para TEF en Cboe es ahora inusualmente grande (digamos 0,05 euros cuando lo normal es 0,01 euros). Esto genera una oportunidad de obtener un beneficio anormal en la creación de mercado de TEF. Los CM que quieran explotar esa oportunidad deben introducir una orden límite dentro del *spread* actual de Cboe. Aquel que responda más rápidamente, adquirirá prioridad de tiempo a la nueva mejor cotización sobre el resto y, por tanto, tendrá más oportunidades de realizar este *spread* anormal. En esta línea, Hendershott y Riordan (2013) muestran que los HFT en Xetra proporcionan liquidez cuando los diferenciales son inusualmente amplios (cuando proveer liquidez está mejor pagado) y demandan liquidez cuando los diferenciales son estrechos (cuando tomar liquidez es más barato).

Todo lo anterior sugiere que el uso de tecnología de negociación de baja latencia, junto con una gestión activa del riesgo, potencia las habilidades de los HFT como CM. En el **cuadro 2** se estima la *horquilla efectiva* exigida por los CM para los activos constituyentes del NIFTY50 en 2013. Si el tomador es un agente informado cabría esperar que tras la transacción los precios se moviesen para reflejar la nueva información. Si el tomador compra (vende) la señal será positiva (negativa), por lo que cabe esperar que el punto medio se ajuste al alza (baja). En ambos casos el precio se mueve en contra de la posición recién adquirida por el CM. El ajuste en precios tras una transacción se denomina *impacto en precios*. Si éste no es cero, la *horquilla realizada* por el CM será menor que la horquilla efectiva. La horquilla realizada es pues la diferencia entre la horquilla efectiva y el impacto en precios, y mide el beneficio del CM neto de costes de selección adversa.

Por ejemplo, supongamos que la horquilla de TEF es 3,45 euros (*ask*) y 3,43 euros (*bid*). Un agente informado introduce una orden agresiva de compra que se ejecuta a 3,45 euros. Tras la transacción, las cotizaciones se ajustan al alza para reflejar la señal positiva sobre el valor del activo (compra). La nueva horquilla de TEF es 3,47 euros (*ask*) y 3,45 euros (*bid*). El punto medio antes de la transacción es $(3,45+3,43)/2 = 3,44$ euros, y tras la transacción es $(3,47+3,45)/2 = 3,46$ euros. Por tanto, se ha producido un impacto en precios de 0,02 euros. La prima inicialmente demandada por el CM es $3,45-3,44 = 0,01$ euros. Sin embargo, la realizada es de $3,45-3,46 = -0,01$ euros. Es decir, el CM pierde al negociar con un agente informado (coste de selección adversa).

El cuadro 2 distingue tres tipos de proveedores de liquidez: HFT, AT de agencia y no AT.

Cuadro 2.

HFT y los costes de crear mercado

<i>Operador</i>	<i>Efectiva</i>	<i>Realizada</i>		<i>Impacto</i>	
HFT	6,68	4,88		1,08	
Otro AT	5,32	2,29	***	2,40	***
NAT	5,14	3,02	***	2,12	***

Este cuadro muestra estadísticos medios diarios de horquilla efectiva, horquilla realizada e impacto en precios para los 50 activos más líquidos del National Stock Exchange of India (NSE) en 2015. Las transacciones se clasifican en función de qué tipo de operador proporciona liquidez: HFT, otros AT, y no AT (NAT). Para una transacción en el momento t , la horquilla efectiva se calcula como la diferencia entre el precio de la transacción p_t y el punto medio del libro en el momento de que esa transacción se produce q_t , multiplicado por el signo de la transacción x_t – si es una compra, $x_t = 1$, si es una venta $x_t = -1$. La horquilla realizada se calcula de forma equivalente, pero utilizando el punto medio al menos 60 segundos después, $t+60$. El impacto en precios es la diferencia entre el punto medio en $t+60$ y el punto medio en t , multiplicado por el signo de la transacción. *** indica diferente al valor para el HFT al 1% de significatividad estadística.

Los HFT del NSE muestran horquillas efectivas medias más altas, en línea con las predicciones teóricas (Foucault *et al.*, 2013) y la evidencia empírica (Hendershott y Riordan, 2013) que sugiere que los HFT reaccionan agresivamente ante disminuciones transitorias en liquidez. Además, la horquilla realizada media de los HFT, que mide los beneficios medios del CM por operación, es mucho mayor para los HFMM, lo que indica unas pérdidas menores frente a agentes informados (menor riesgo de selección adversa). En consonancia con esta interpretación, las órdenes agresivas a las que los HFT proporcionan liquidez tienen un impacto medio menor en los precios, lo que significa que los HFMM experimentan movimientos adversos en precios con menor frecuencia.

Si los HFT operan con unos costes de creación de mercado menores y, además, la industria del HFT es altamente competitiva, tal y como sugiere el estudio de Boehmer *et al.* (2018), deberíamos esperar que los HFMM trasladen sus menores costes de operar a sus clientes en forma de márgenes más ajustados. En este sentido, Hendershott y Riordan (2013) muestran que, en *Xetra*, la negociación algorítmica ofrece las mejores cotizaciones del mercado más a menudo que la no algorítmica. Además, Subrahmanyam y Zheng (2014) encuentran que en el Nasdaq los HFT colocan el 78 % de sus órdenes límite en los tres primeros niveles del libro. La velocidad relativa constituye, por tanto, una ventaja competitiva en la creación de mercado.

4.2. Arbitraje de baja latencia

Por arbitraje de baja latencia se entiende explotar oportunidades de arbitraje de muy corta duración entre mercados para el mismo activo o entre activos relacionados¹⁸. Supongamos un algoritmo de negociación que busca aprovechar las oportunidades de arbitraje entre el ETF SPY, un fondo sobre el S&P500 negociado en el NYSE, y el contrato de futuros E-mini (ES), también sobre el S&P500, negociado en el CME. Dado que tienen el mismo subyacente, los precios de estos activos deberían moverse al unísono. Como en cualquier estrategia de arbitraje, el algoritmo hará un seguimiento de los precios de ambos valores a lo largo del tiempo tratando de captar desviaciones significativas. Si, por ejemplo, el precio de SPY es alto en relación con el precio de ES, el algoritmo enviará inmediatamente órdenes de mercado al CME para comprar ES y órdenes de mercado al NYSE para vender SPY. Nuestro algoritmo se enfrenta a otros algoritmos similares que intentan explotar la misma oportunidad de arbitraje. La latencia relativa de cada arbitrajista va a ser, por tanto, fundamental para determinar cuántas oportunidades de arbitraje explotará cada algoritmo (Baron *et al.*, 2018).

Budish, Crampton y Shim (2015) observan que la correlación entre las series de puntos medios del SPY y ES es prácticamente uno para frecuencias bajas, pero dicha correlación se rompe para frecuencias altas. Por ejemplo, para una frecuencia de 10 (1) ms la correlación es de sólo 0,1016 (0,0080). Esta ruptura de las correlaciones a frecuencias suficientemente altas conlleva la existencia de oportunidades de arbitraje simples, mecánicas, de ultracorta duración, que están disponibles para quienes sean lo suficientemente rápidos para explotarlas. Dada la arquitectura actual de los mercados financieros, este resultado es esperable. SPY y ES se negocian de forma continua, simultáneamente, pero cada uno en su propio mercado electrónico, con su propio libro de órdenes, totalmente por separado. Nada garantiza, por tanto, que los precios de SPY y ES se muevan al mismo tiempo en frecuencias tan altas.

Budish *et al.* (2015) también obtienen que la correlación entre el SPY y ES en frecuencias altas ha aumentado entre 2005 y 2011. Así, para una frecuencia de 100 ms, la correlación entre el SPY y ES, cercana a cero en 2005, aumentó hasta casi 0,5 en 2011. Esta tendencia creciente refleja el impacto del HFT y su competencia en latencia. Las correlaciones han aumentado porque el mercado se ha vuelto más rápido y, por ende, las distorsiones en precios se corrigen cada vez más rápido. Aun así, si la frecuencia es lo suficientemente alta, las correlaciones entre el SPY y ES son esencialmente nulas. Como consecuencia de lo anterior, la duración media de las oportunidades de arbitraje entre SPY y ES se ha reducido con el tiempo, de una mediana de 97 ms en 2005 a 7 ms en 2011. Esto significa que la competencia en latencia entre las empresas de HFT ha ido subiendo el listón de cuán rápido hay que ser para poder captar las oportunidades de arbitraje. Los beneficios en juego, sin embargo, se han mantenido estables a lo largo del tiempo y se estiman en 75 millones de dólares por año.

¹⁸ En finanzas, el arbitraje consiste en la compra y venta simultánea de un mismo activo en diferentes mercados con el fin de beneficiarse de pequeñas diferencias en el precio. El arbitraje también puede implicar instrumentos financieros diferentes pero cuyos precios están teóricamente (derivados y subyacentes) o estadísticamente (por ejemplo, acciones de Coca Cola y Pepsi) ligados.

El caso de SPY y ES sólo es un ejemplo de instrumentos financieros entre los que se puede hacer arbitraje de baja latencia. Hay cientos de pares de instrumentos cuyos precios están altamente correlacionados y son suficientemente líquidos como para generar beneficios significativos.

Además, actualmente el mismo activo negocia en múltiples plataformas a la vez. Así podemos arbitrar entre el SPY en el NYSE y el Nasdaq, en acciones de TEF en Bolsa de Madrid y en Cboe, etc. Tenemos también el arbitraje estadístico, que se realiza entre acciones de empresas diferentes, pero altamente ligadas (Apple y Google, Exxon-Mobil y Chevron, Lowe's y Home Depot, etc). El fenómeno de ruptura de correlación a altas frecuencias que Budish *et al.* (2015) observan entre SPY y ES se da también entre todos estos pares de activos.

En otro ejemplo de arbitraje de baja latencia, Aquilina, Budish y O'Neil (2022) estudian conjuntamente aquellas estrategias que implican reaccionar rápidamente a señales del mercado para tomar órdenes límite que estén en dinero. Supongamos una señal informativa tras la cual un HFMM se apresura a cancelar o revisar cotizaciones obsoletas (sus órdenes límite en dinero), mientras que un HFB se lanza rápidamente a explotar oportunidades de arbitraje, generando una *carrera de velocidad* entre ambos. El HFMM perderá la carrera si su mensaje de cancelación o revisión llega después que la orden haya sido tomada por el HFB, mientras que este último será el perdedor si su orden llega después de que el HFMM haya retirado la orden en dinero del libro u otro HFB más rápido haya tomado ya la orden. El perdedor recibirá un mensaje del mercado de "fallido", indicando que su instrucción no ha podido ejecutarse. En cambio, el ganador recibirá un mensaje de aceptación.

Aquilina *et al.* (2022) tienen acceso a una base de datos única del London Stock Exchange (LSE) que contiene información sobre todos los mensajes entrantes y salientes enviados al/por el sistema, incluyendo los fallidos. Con ella identifican todas las carreras de velocidad para los activos constituyentes del FTSE100 entre agosto y octubre del 2015. Los resultados de su análisis muestran que estas carreras de velocidad son frecuentes (537 carreras por activo/día; 1 carrera por activo/minuto, aprox.), ultrarrápidas (la velocidad de respuesta del ganador supera a la del perdedor más rápido en sólo 5-10 μ s) e importantes (representan el 22 % del volumen medio diario). En su mayoría, estas carreras las ganan las empresas de HFT que son relativamente más rápidas – el top 3 (6) gana el 55 % (82 %) de las carreras. Si bien los beneficios por carrera son relativamente pequeños (2 libras en media), el beneficio total en juego estaría en torno a los 60 millones de libras por año sólo en el mercado británico. Extrapolando al mercado bursátil global estiman un montante de 5.000 millones de dólares anuales. La cuantía aumentaría si se incluyeran otros activos que también negocian en mercados electrónicos, como futuros, divisas, deuda pública, etcétera.

4.3. Negociación direccional

La negociación o especulación direccional consiste en hacer apuestas basadas en previsiones de cambios en los precios a corto plazo (*i.e.*, comprar en previsión de una subida,

vender en previsión de una bajada). El HFT utiliza su superior capacidad y velocidad para procesar (y reaccionar a) la información del mercado rápidamente e intentar predecir movimientos en precios a muy corto plazo. Para establecer sus posiciones especulativas, los algoritmos de los HFT negocian de forma agresiva, demandando liquidez.

Considere un algoritmo de HFT que utiliza cambios de precio en un contrato de futuro sobre un índice bursátil como señales para anticipar cambios de precio en los componentes del índice. Si el precio del futuro aumenta, el algoritmo compra agresivamente los constituyentes que están más correlacionados con el índice. La latencia del HFT es fundamental, ya que éste debe actuar antes de que los precios de contado se ajusten a la señal. Así, Hendershott y Riordan (2013) muestran que los HFT del Xetra son más propensos que otros tipos de operadores a comprar (vender) tras rendimientos positivos (negativos) en los últimos 30 segundos en contratos de futuro sobre el índice bursátil de referencia.

Otro ejemplo sería un algoritmo de HFT que utilice información en tiempo real sobre la actividad del mercado para predecir negociación persistente y potencialmente informada, con el fin de anticiparse a la misma y beneficiarse después de su impacto en precios. En este ejemplo, el HFT hace *free-riding* de la adquisición de información valiosa por parte de otros operadores. Hirschey (2020) estudia la negociación anticipativa por el HFT en el Nasdaq. Muestra que los algoritmos que trabajan las órdenes de los agentes informados trocean la orden matriz (grande) en múltiples órdenes pequeñas que luego ejecutan a lo largo del tiempo (*order splitting*), dejando un rastro que los algoritmos de HFT pueden seguir. Este rastro tiene forma de niveles anormalmente altos en la autocorrelación de la serie del volumen neto (*i.e.*, volumen comprado menos vendido). La capacidad de anticipación del HFT es mayor en el caso de empresas pequeñas, lo que sugiere que los algoritmos en agencia tienen más difícil ocultar su rastro a los HFT cuando operan en activos poco líquidos. Hirschey muestra también que el diferencial entre la rentabilidad de aquellos activos que el HFT compra y aquellos que vende agresivamente es estrictamente positivo, sugiriendo que los HFT detectan negociación informada y, con ello, logran prever cambios permanentes en los precios.

Esta actividad de *free-riding* no es inocua para los intereses de los agentes informados, ya que crea competencia en la explotación de la información. De hecho, Hirschey (2020) muestra que la competencia del HFT aumenta los costes de ejecución de los agentes informados, en forma de un mayor impacto en precios. Para evitar ser detectados los agentes informados deberían negociar de forma menos agresiva. De hecho, Hirschey encuentra que cuando son agresivos, su flujo de órdenes futuro se vuelve más predecible y la competencia por parte del HFT se intensifica. No obstante, negociar de forma menos agresiva, espaciando más la ejecución de la orden en el tiempo, aumentaría el tiempo necesario para poder ejecutar un cambio de posición grande.

Van Kervel y Menkveld (2019) estudian el comportamiento de los HFMM cuando interactúan con órdenes grandes de inversores institucionales. El estudio muestra que, inicialmente, los HFT proporcionan liquidez a las órdenes institucionales, cumpliendo con su papel de CM. Sin embargo, cuando concluyen que están negociando contra órdenes con contenido

informativo, cambian de dirección y empiezan a competir con los institucionales. Denominan a esta estrategia *back-running*. El proceso de aprendizaje es lento, varias horas en media, por lo que sólo acaban compitiendo con las órdenes más grandes o que tardan más tiempo en ejecutarse completamente. Aun así, el proceso es más rápido cuando la orden grande es de venta, ya que los institucionales son más agresivos cuando venden, aumentando la probabilidad de ser detectados. Es posible también que los inversores institucionales estén mejor informados sobre acciones que ya poseen que sobre las que no poseen y que, por tanto, sus órdenes de venta sean más informativas que sus órdenes de compra. Así, el algoritmo del HFT podría estar programado para iniciar el *back-running* mucho antes sobre una orden institucional de venta que sobre una de compra. Al igual que el trabajo de Hirschey (2020), van Kern and Menkveld (2019) muestran que estos algoritmos de HFT de detección de patrones generan una externalidad negativa en los agentes informados en forma de mayores costes de ejecución.

Un último ejemplo de negociación direccional sería la reacción a información pública (*news-reaction strategy*). El HFT oportunista explota su velocidad para negociar con el contenido informativo de una señal pública en los instantes posteriores al anuncio y antes de que los precios completen su ajuste. Diversos trabajos empíricos aportan evidencia de esta estrategia, ya sea sobre anuncios macroeconómicos (Brogaard *et al.*, 2014) o corporativos (Chordia y Miao, 2019). Scholtus, van Dijk y Frijns (2014) estiman que un retraso de más de 300 ms en reaccionar a un anuncio público reduce la rentabilidad de esta estrategia significativamente.

El **cuadro 3** proporciona un resumen de las principales ideas desarrolladas en este apartado.

Cuadro 3.

Estrategias más comunes en el HFT

<i>Estrategia</i>	<i>Objetivo</i>	<i>Ventajas</i>	<i>Ejemplos</i>
Creación de mercado.	Generar beneficio mediante la provisión de liquidez.	<ul style="list-style-type: none"> (a) Menores costes de crear mercado (selección adversa, gestión de inventario, costes operativos). (b) Bajos costes de seguimiento de órdenes. (c) Mayor capacidad de repuesta para aprovechar oportunidades de beneficio anormal en la provisión de liquidez. (d) Alta competitividad, horquillas de precios más estrechas. 	<ul style="list-style-type: none"> (a) Provisión de liquidez en múltiples plataformas simultáneamente. (b) Gestión activa del riesgo; seguimiento intensivo de órdenes. (c) Altas tasas de cancelaciones y revisiones de órdenes.

Cuadro 3. (continuación)

Estrategias más comunes en el HFT

<i>Estrategia</i>	<i>Objetivo</i>	<i>Ventajas</i>	<i>Ejemplos</i>
Arbitraje de baja latencia.	Explotar oportunidades de arbitraje de muy corta duración.	Algoritmos capaces de explotar oportunidades de arbitraje no aprovechables a la velocidad de respuesta del ser humano.	(a) Arbitraje entre futuros sobre índices y contado (ETF). (b) Arbitraje multiplataforma para un mismo activo. (c) Arbitraje estadístico entre activos altamente correlacionados. (d) Carreras de velocidad.
Negociación direccional.	Especular en base a previsiones de cambios de precios a muy corto plazo.	Algoritmos capaces de reaccionar a velocidades extremas ante señales informativas.	(a) Especular en el mercado de contado en base a señales provenientes del mercado de futuros (b) Estrategias de anticipación de negociación informada (c) <i>Back-running</i> (d) <i>News-reaction</i>

Este cuadro resume las estrategias más comunes en el HFT, su objetivo, las ventajas del HFT frente a otros operadores y ejemplos.

5. IMPACTO DEL HFT SOBRE LA CALIDAD DEL MERCADO

En lo que resta, abordamos la principal cuestión de este estudio: ¿cuál ha sido el impacto del HFT sobre la calidad del mercado? Esta labor nos permitirá también exponer argumentos tanto a favor como en contra del HFT.

Por calidad del mercado entendemos altos niveles de liquidez y de eficiencia en precios. En finanzas, liquidez es la cualidad de poder comprar o vender cuando y cuanto uno quiera a bajo coste y sin tener que hacer grandes concesiones en el precio. Para medir la liquidez de un activo, hay que responder básicamente a dos preguntas: (1) ¿Cuáles son los costes implícitos de comprar o vender de forma inmediata un determinado volumen de títulos? La respuesta a esta pregunta es lo que se conoce como *costes de inmediatez*, y se miden mediante horquillas de precios o *spreads*. Un mayor *spread* implica mayores costes de inmediatez, esto es, menor liquidez. (2) ¿Cuánto podemos llegar a comprar o vender sin alterar significativamente el precio? La respuesta a esta pregunta se conoce como *profundidad*, y depende del volumen ofrecido a (o

cerca de) las mejores cotizaciones en el libro de órdenes. A mayor volumen ofrecido, mayor profundidad, es decir, más liquidez. Mayor liquidez se asocia a menores costes de negociar y mayor competitividad del mercado, pero también a mayor eficiencia en precios (por ejemplo, Chordia, Roll y Subrahmanyam, 2008) y menor coste de oportunidad del capital para las empresas cotizadas (por ejemplo, Amihud y Mendelson, 1986).

Por otro lado, un precio es eficiente si incorpora toda la información disponible en un instante determinado. Un precio eficiente es un precio justo, en el sentido de que refleja la expectativa que tiene el mercado sobre el verdadero valor del activo dada la información disponible. Bajo la hipótesis de eficiencia los precios cambian porque llega nueva información al mercado, donde *nueva* significa no predecible. Bajo la hipótesis de eficiencia, desviaciones respecto al precio eficiente (*ruido*) son posibles, pero se corrigen rápidamente. A la hora de medir la eficiencia en precios, los académicos responden a preguntas como: ¿cuán predecibles son los cambios de precios? ¿Cuánto ruido hay en los cambios de precios? (por ejemplo, Hendershott y Menkveld, 2014; Comerton-Forde y Putnins, 2015).

Finalmente, el proceso mediante el cual la nueva información se incorpora a los precios se conoce como formación del precio (*price discovery*). Las propiedades más deseables de todo proceso de formación del precio serían rapidez y precisión. En periodos de alta intensidad en la formación del precio la volatilidad aumenta y la liquidez sufre (por ejemplo, Glosten y Milgrom, 1985). Por tanto, cuanto más rápidamente y de forma más precisa se ajusten los precios a la nueva información, menos duraderas serán las distorsiones en liquidez. Liquidez y formación del precio son, por tanto, conceptos interrelacionados. Estudios sobre el proceso de formación del precio, responden a preguntas como: ¿cuánto contribuyen determinado tipo de mensajes/operadores a la volatilidad del precio justo? ¿Cuán rápido se ajustan los precios a la nueva información? (por ejemplo, Hasbrouck, 1995; Brogaard *et al.*, 2014, 2019; Chordia y Miao, 2021).

5.1. HFT y liquidez

Hemos visto que hay dos estrategias canónicas de HFT: creación de mercado y negociación oportunista. En términos generales, la teoría existente predice un efecto positivo de la creación de mercado y un efecto negativo de la negociación oportunista sobre la liquidez.

Los HFT explotan sus ventajas en tecnología y velocidad para reducir los costes de crear mercado. En un entorno altamente competitivo, esperaríamos que los HFMM trasladaran sus menores costes relativos a las primas y descuentos que demandan por proporcionar liquidez. De ser así, el *spread* consolidado de los HFMM debería ser menor y la presencia de éstos en las mejores cotizaciones *ask* y *bid* más frecuente que para el resto de los operadores. Cabe esperar, por tanto, que mayor actividad de los HFMM se asocie con una mayor liquidez. Sin embargo, algunas voces críticas, tanto en el ámbito profesional como en el académico, sostienen que una dependencia excesiva en proveedores de liquidez endógenos (como los

HFMM) puede aumentar la fragilidad del mercado y el riesgo sistemático (por ejemplo, Anand y Venkataraman, 2016).

En lo que respecta a la negociación oportunista, la teoría predice que los HFB, independientemente de si los modelizamos como arbitrajistas (Foucault, Kozhan y Wah, 2017), especuladores (Biais, Foucault y Moinas, 2015) o *news traders* (Foucault, Hombert y Roçu, 2016), imponen una externalidad negativa a los proveedores de liquidez más lentos en forma de costes de selección adversa más elevados. Se espera, por tanto, que una mayor actividad por parte de estos HFT resulte en un aumento en los *spreads* y, por tanto, una menor liquidez. Por otro lado, la negociación oportunista puede acelerar la incorporación de la nueva información a los precios, lo que potencialmente puede beneficiar a la liquidez.

¿Qué concluye la investigación empírica? Los primeros estudios empíricos que analizan el impacto de la HFT en la liquidez no diferencian entre estrategias de HFT. El efecto global del HFT en la liquidez dependerá, en última instancia, de la importancia relativa de cada una de sus estrategias canónicas, lo que puede depender a su vez del mercado, periodo y muestra de activos que se examine. Tampoco olvidemos que una empresa de HFT no tiene por qué especializarse en una única estrategia canónica. Así, el flujo de mensajes de un HFT es el reflejo de una mezcla de estrategias (Boehmer *et al.*, 2018). Hendershott, Jones y Menkveld (2011) examinan la relación entre AT y liquidez en mercados norteamericanos entre 2001 y 2006, etapas donde el HFT era todavía incipiente. Recurren al tráfico de mensajes, escalado por volumen negociado, como medida indirecta de la actividad del AT. Sus análisis revelan que aumentos de su *proxy* de AT a lo largo del tiempo se asocian a mejoras en diversos indicadores de liquidez. Dicha mejora en liquidez se debe, principalmente, a un menor riesgo de asimetrías de información. Para establecer causalidad utilizan una mejora tecnológica en el NYSE: la introducción de *Auto-Quote*. Esta innovación supuso un impulso importante para el AT en EE. UU. ya que, por primera vez, se ofrecía información en tiempo real sobre las mejores cotizaciones. Tras la introducción de *Auto-Quote* la actividad del AT aumentó y este incremento mejoró la liquidez.

Siguiendo el mismo enfoque instrumental, Boehmer, Fong y Wu (2020) estudian la introducción del servicio de colocación en 42 mercados de todo el mundo entre 2001 y 2011. La colocación reduce la latencia, haciendo al mercado más atractivo para el HFT, pero no tiene por qué verse impulsada por mejoras en liquidez, ni tener efecto alguno por sí misma en la calidad del mercado. Esto hace de la colocación un buen instrumento para el HFT. Por su parte, Riordan y Storckenmaier (2012) utilizan como instrumento una mejora en la tecnología de negociación del *Xetra*, que redujo la latencia de 50 ms a 10 ms. Ambos estudios llegan a la misma conclusión que Hendershott *et al.* (2011): mayor actividad del HFT se asocia a mayor liquidez y el canal a través del cual se produce dicha mejora es una reducción sustancial en los costes de selección adversa que soportan los proveedores de liquidez.

Estos estudios primigenios tienen la limitación de no poder distinguir la actividad del HFT de la actividad de otro tipo de AT. En este sentido, Hasbrouck y Saar (2013) proponen usar las carreras estratégicas (*SRuns*, ver sección 3) como medida indirecta para capturar

actividad específica del HFT y aislar, así, el HFT de otras formas de AT¹⁹. Encuentran que aumentos en la actividad del HFT (más *SRuns*) se asocia con mejoras en liquidez. Además, la literatura existente apunta a la creación de mercado como la estrategia canónica dominante en la industria del HFT. Tal dominancia podría sesgar los resultados de estos estudios, llevándonos a concluir que la relación positiva entre HFT y liquidez se extiende a toda la pléthora de estrategias que se engloban bajo la marca “HFT”.

Estudios más recientes distinguen entre estrategias canónicas. Por ejemplo, Chakrabarty, Pankaj, Shkilko y Sokolov (2021) examinan una iniciativa reguladora de la SEC de noviembre de 2011 conocida como *CCTP (Credit and Capital Thresholds Provision)*, dirigida a prohibir una práctica en la industria conocida como acceso “sin filtro” o “desnudo” (*unfiltered* o *naked*) al mercado²⁰. El nuevo protocolo exigía a los *brokers* realizar comprobaciones en tiempo real de las posiciones de sus clientes en múltiples mercados e instrumentos antes de permitirles operar, prohibiendo *de facto* el acceso desnudo. El protocolo tuvo el efecto colateral, seguramente no deseado, de aumentar la latencia del sistema, ya que comprobar la posición del cliente requeriría de tiempo adicional. No obstante, el efecto no fue el mismo para todas las empresas de HFT, ya que algunas estaban registradas como *broker-dealers*, eran miembros del mercado y, por tanto, ya estaban obligadas a cumplir los umbrales de crédito y capital. Sólo las empresas de HFT no registradas y que usaban el acceso sin filtro al mercado se vieron perjudicadas. Chakrabarty *et al.* (2021) muestran que estas últimas eran mayormente HFB, que redujeron sustancialmente su participación. Como consecuencia, el riesgo de selección adversa de los proveedores de liquidez disminuyó y la liquidez del mercado aumentó.

Esta relación negativa entre HFB y liquidez se ve apoyada por otros estudios. Brogaard, Hendershott y Riordan (2017) encuentran que mientras que la venta en corto de otros operadores mejora la liquidez al mejorar la eficiencia en precios, la de los HFT impone un mayor riesgo de selección adversa sobre los creadores de mercado, lo que reduce la liquidez. Foucault, Kozhan y Tham (2017) estudian el impacto de un cambio tecnológico en el mercado de divisas que aumenta la velocidad relativa de los arbitrajes de baja latencia. Este *shock* a la latencia aumentó el riesgo de selección adversa. Por otro lado, Shkilko y Sokolov (2020) muestran que reducciones en la latencia de los HFT que arbitran entre el CME y el NYSE durante episodios de mal tiempo van acompañadas de mejoras en la liquidez del NYSE. Todos estos estudios corroboran que el HFT oportunista ejerce una externalidad negativa sobre los proveedores de liquidez en forma de mayores costes de crear mercado.

Finalmente, Brogaard y Garriott (2019) aprovechan la entrada secuencial de once empresas de HFT a lo largo de un periodo de cuatro años en un mercado alternativo cana-

¹⁹ Chakrabarty *et al.* (2022) proporcionan evidencia empírica que apoya este supuesto.

²⁰ Es habitual que los *brokers* den acceso al mercado a sus clientes a través de su propia infraestructura. Esto se conoce como *direct market access (DMA)*. Otra práctica habitual es el *sponsored market access*, por la que el cliente utiliza su propia infraestructura para operar, pero con el código identificador del *broker*. Normalmente, el *broker* tendría la responsabilidad de comprobar que sus clientes satisfacen los umbrales de crédito y capital impuestos por el mercado antes de permitirles operar en el sistema. El acceso “desnudo” implica que los clientes acceden directamente saltándose el control del *broker*.

diense, Alpha, para estudiar cómo la competencia entre empresas de HFT afecta a la liquidez. El estudio muestra que el *spread* de Alpha converge hacia el *spread* del Toronto Stock Exchange a medida que aumenta el número de empresas de HFT operando en el mercado, sugiriendo que la competencia entre empresas de HFT tiene un efecto positivo sobre la liquidez. Además, ese efecto es persistente y se traduce en costes de ejecución efectivos menores para los operadores no algorítmicos. Como cabría esperar, atribuyen la mejora de la liquidez a la competencia entre los HFMM.

5.2. HTF y formación de precios

¿Son las transacciones y cotizaciones de los HFT informativas? Es decir, ¿contribuyen a la formación del precio? La actividad del HFT, ¿acelera la incorporación de nueva información a los precios? ¿Ha aumentado la eficiencia en precios tras la irrupción del HFT? En esta sección se exponen las conclusiones más relevantes de la investigación empírica que intenta dar respuesta a estas preguntas.

Los HFB basan sus estrategias en negociar sobre señales públicas más rápido que los demás. Por tanto, cabe esperar que su actividad provoque que las oportunidades de arbitraje desaparezcan más rápidamente, que la incorporación de nueva información se acelere y que las distorsiones en precios se corrijan más rápido. De ser así, el HFT oportunista debería contribuir a mejorar la formación del precio, al menos a altas frecuencias. Esta lógica, estándar en modelos de negociación con agentes informados (por ejemplo, O'Hara, 1995; Foucault, Pagano y Röell, 2007), plantea problemas cuando se aplica al HFT. Así, Foucault, Hombert y Rosu (2016) proponen un modelo en el que los HFB negociando con información a corto plazo imponen costes de selección adversa sobre agentes informados que negocian con información a largo plazo. Si esos costes son altos, los agentes informados pueden decidir no negociar, retrasando la incorporación de la información fundamental al precio. En la misma línea, Weller (2018) sostiene que un excesivo por parte de los HFT (recuerde la estrategia de *back-running*) podría incluso desincentivar la adquisición de información fundamental. Finalmente, Dugast y Foucault (2018) proponen un marco teórico en el que los HFT negociando rápidamente en base a información bruta, no contrastada, inyectan ruido en precios. En su modelo, procesar la información filtra el ruido, pero requiere de cierto tiempo que los HFT no tienen. Si el coste de la información bruta disminuye también lo hace la demanda de información procesada y, por ende, la eficiencia en precios a largo plazo.

En cuanto a los HFMM, sabemos que su intensa actividad de seguimiento de órdenes les permite reajustar sus cotizaciones con rapidez y frecuencia en respuesta a todo tipo de señales y noticias del mercado. En consecuencia, sus cotizaciones deberían incorporar información relevante más rápidamente, es decir, ser más informativas sobre el verdadero valor del activo que las de otros operadores, y sus ajustes deberían contribuir a la formación de precios. Además, los HFMM se enfrentan a un coste de gestión de inventario menor que otros operadores de mercado, lo que debería traducirse en menores distorsiones en los precios cau-

sadas por la gestión de inventario (Hendershott y Menkveld, 2014), es decir, menor ruido en precios, aumentando la eficiencia.

Los primeros trabajos empíricos en analizar el impacto del HFT en la eficiencia en precios se fijan en el efecto agregado del AT. Para el mercado de divisas, Chaboud, Chiquoine, Hjalmarsson y Vega (2014) observan que mayor AT se asocia con mayor eficiencia en precios. Mediante métodos estadísticos, establecen que esta relación es causal y que tanto los HFB, a través del arbitraje de baja latencia, como los HFMM, a través de la actualización rápida y continuada de sus cotizaciones, contribuyen a hacer más eficientes los precios de este mercado. Conrad *et al.* (2015) encuentran que activos con mayor actividad del HFT, medida a través del *high-frequency quoting (HFQ)* (ver sección 3), tienen precios más eficientes. Para establecer causalidad utilizan la introducción del sistema de negociación Arrowhead en el Tokio Stock Exchange en enero de 2010, que redujo la latencia del sistema. Encuentran que mayor actividad del HFT, instrumentalizado a través del *shock* exógeno, resultó en mejoras tanto de eficiencia como de liquidez.

La información se refleja en las cotizaciones de los proveedores de liquidez cuando éstos revisan sus órdenes límite en el libro como respuesta a señales valiosas, tanto externas (por ejemplo, anuncios corporativos) como emanadas de la propia negociación (por ejemplo, transacciones). Algunas de estas últimas pueden reflejar a su vez señales informativas más primitivas, adquiridas por agentes informados. Modelos clásicos de formación de precios presuponen que los agentes informados toman liquidez porque su ventaja informativa es precedera²¹. Por tanto, la demanda de liquidez es informativa porque existe una probabilidad estrictamente positiva de que las órdenes agresivas reflejen negociación informada. La teoría sobre HFT predice que las cotizaciones de los HFMM incorporan la información más rápidamente, reduciendo así las oportunidades tanto de agentes informados como de operadores oportunistas de extraer rentas a su costa (por ejemplo, Hoffmann, 2014; Jovanovic y Menkveld, 2016; Bhattacharya y Saar, 2021). Como resultado, el contenido informativo de la demanda de liquidez podría haber disminuido tras la aparición del HFT. En esta línea, Riordan y Storckenmaier (2012) observan que tras un *shock* a la latencia del mercado alemán Xetra en 2007, el proceso de formación del precio cambió: las transacciones se volvieron menos informativas, mientras que el contenido informativo de las cotizaciones aumentó. En consecuencia, el peso relativo de la demanda de liquidez en la formación del precio disminuyó.

Estudios posteriores distinguen entre estrategias de HFT. Brogaard, Hendershott y Riordan (2014) estudian cómo el HFT oportunista contribuye a la eficiencia en precios. Utilizan una base de datos no pública del Nasdaq que identifica las transacciones que involucran HFT para una muestra de 120 activos entre 2008 y 2010. Mediante técnicas estadísticas, descomponen el precio observado en un componente informativo (precio justo) y un componente transitorio (ruido), para después evaluar cómo impacta el HFT en ambos componentes. Sus resultados

²¹ Véase Kyle (1985), Glosten y Milgrom (1985), Easley y O'Hara (1987), Easley, Kiefer, O'Hara y Paperman (1992), Holden y Subrahmanyam (1992), entre otros muchos.

muestran que el HFT oportunista mejora la eficiencia en precios de dos formas diferentes. En primer lugar, negocian agresivamente en la dirección de cambios permanentes en los precios, lo que es coherente con una exitosa negociación direccional: anticipan cambios permanentes en el precio a corto plazo, toman posiciones agresivamente y, al hacerlo, aceleran la incorporación de la nueva información. Además, las transacciones iniciadas por los HFT son más informativas que las iniciadas por otros tipos de operadores. En segundo lugar, los HFT oportunistas negocian en contra de movimientos transitorios en los precios, contra desviaciones temporales entre el precio observado y el precio justo, ayudando así a disminuir el ruido en el precio. Este resultado es consistente con un exitoso arbitraje de baja latencia.

El estudio anterior ignora el componente más importante del tráfico de mensajes: las órdenes límite. El uso intensivo de estas órdenes es una de las características más sobresalientes de los mercados actuales (O'Hara, 2015). En su siguiente estudio, Brogaard *et al.* (2019) proporcionan un estudio más completo y detallado sobre el papel que el HFT juega en el proceso de formación de precios. Utilizan datos del mercado de valores canadiense, donde identifican 61 empresas de HFT de entre un total de 1.706 operadores en el mercado. En media por día, los HFT aportan el 53 % del tráfico total de mensajes. Éste se compone en un 48 % de órdenes límite nuevas y en un 47 % de cancelaciones/revisiones de órdenes límite ya en el libro. Las órdenes de mercado representan menos del 5 % del total de mensajes. Además, el 50 % de toda la actividad se centra en las mejores cotizaciones del mercado, donde los HFT son mucho más activos que otros operadores.

Al estudiar el contenido informativo medio de los diferentes tipos de mensajes, Brogaard *et al.* (2019) encuentran que las órdenes agresivas tienen un mayor impacto medio en precios, seguidas de las órdenes límite y las cancelaciones que alteran las mejores cotizaciones. Toda la actividad que ocurre más allá de esas mejores cotizaciones es irrelevante en la formación del precio. Al comparar los mensajes del HFT con el resto de los operadores, encuentran que las órdenes de los HFT son, en media, más informativas que órdenes similares de otros operadores. Como resultado de lo anterior, al calcular cuánto de la volatilidad del precio justo es atribuible a cada tipo de orden (*information share*) encuentran que la contribución de los HFT es del 42,3 %, unos 10 puntos porcentuales más que la del resto de operadores (33 %). El resto sería atribuible a información no relacionada con el flujo de órdenes. A pesar de que las órdenes agresivas tienen, en media, mayor contenido informativo, son mucho menos frecuentes que las órdenes límite. Como consecuencia, las órdenes de mercado explican un 30 % de la formación de precios mientras que las órdenes límite explican un 45 %. Como el HFT es responsable de la mayor parte del flujo de órdenes límite, se convierten también en los principales contribuyentes al proceso de formación del precio.

6. IMPACTO DEL HFT: OTRAS INQUIETUDES

La investigación académica sugiere que el impacto del HFT en la calidad de los mercados financieros tiene sus luces y sus sombras. Por un lado, el HFT globalmente considerado ha contribuido a aumentar la liquidez del mercado, ha acelerado y redefinido el proceso de formación de precios y ha aumentado la eficiencia en precios al menos a frecuencias altas. Sin

embargo, ciertas estrategias que se incluyen dentro del paraguas del HFT generan externalidades negativas en otros operadores y podrían reducir la liquidez. Finalizamos este trabajo dando unas pinceladas sobre algunas de las preocupaciones más recurrentes relacionadas con el HFT, expuestas por reguladores, foros de profesionales y trabajos académicos. Estas inquietudes, en muchos casos, han recibido una atención que se antoja insuficiente por parte de la investigación académica, por lo que podemos considerarlas como no resueltas.

6.1. La carrera tecnológica

Las empresas de HFT compiten ferozmente entre sí para explotar unas oportunidades de beneficio que, obviamente, son limitadas. Las empresas más rápidas capturan un mayor porcentaje de éstas y, con ello, una mayor cuota de mercado. Por este motivo, los HFT no reparan en gastos para reducir su latencia relativa. Una de las principales críticas que suscita el HFT es que esta feroz competencia en latencia puede conducir a una carrera tecnológica que puede no ser óptima desde el punto de vista del bienestar social (Biais, Foucault y Moinas, 2015)²². El principal temor es que podría reducir la competencia en el sector, ya que las empresas de HFT más lentas podrían ser expulsadas del mercado. Asimismo, el alto coste de adquirir la tecnología necesaria para poder competir con las empresas de HFT ya establecidas podría convertirse en una barrera de entrada para nuevos competidores. Una mayor concentración podría resultar en un aumento de los costes implícitos por negociar (menor liquidez) y, con ello, un mayor coste de capital para las empresas emisoras (por ejemplo, Amihud, Mendelson y Pedersen, 2013). Estas voces críticas apremian a los mercados a que adopten medidas para frenar la carrera tecnológica.

¿Cómo pueden los reguladores detener esta carrera tecnológica o, al menos, evitar que sea perjudicial? Las soluciones sugeridas consisten en ralentizar al HFT para eliminar las ventajas o jerarquías en velocidad, y así conseguir un tablero de juego más equitativo. Una posibilidad es imponer una latencia mínima al sistema, de manera que se reduzcan los incentivos a adquirir la tecnología más rápida. Otra opción es introducir retrasos intencionados y sistemáticos a la velocidad de procesamiento de órdenes (*speed bumps*) de manera que las diferencias en latencia de apenas unos pocos milisegundos no tengan valor. Estos retrasos pueden ser aleatorios, de forma que no sea el mismo para todos los mensajes (por ejemplo, tiempo de procesamiento + retraso aleatorio entre 0 y 10 ms), o puede ser uniforme. Pueden ser simétricos (todos los operadores experimentan el mismo retraso) o asimétricos (por ejemplo, solamente se ralentizan las órdenes que demandan liquidez). También es posible que discriminen entre tipo de mensaje (por ejemplo, se aplica a todo mensaje excepto a cancelaciones)²³. Observe que

²² El término utilizado es *technological arms race*. *Arms race* se puede traducir como “carrera armamentística”, en referencia a la competencia entre naciones para aumentar el tamaño y la calidad de los recursos militares.

²³ Algunos mercados norteamericanos han experimentado ya con estas *speed bumps*, por ejemplo Investors Exchange (IEX) en 2013; Aequitas NEO Exchange en 2015, o el TSX Alpha Exchange en 2015. En Europa, el mercado alemán Eurex Exchange impuso una *speed bump* sobre tomadores de liquidez aleatoria (de 1 a 3 ms) en junio de 2019.

estas medidas suponen una restricción vinculante sólo para operadores cuyo éxito depende de la velocidad. Además, sólo afectan a la latencia del mercado. Hipotéticamente, el HFT podría sustituir mayor latencia de mercado por menor latencia individual.

El 17 de junio de 2016 la SEC aprobó la conversión del Investors Exchange (IEX) de *dark pool* a National Securities Exchange. El IEX se convirtió así en el primer mercado electrónico en EE. UU. con un tope de velocidad, ya implantado desde su etapa anterior. En EE. UU., la *Order Protection Rule* obliga a que toda orden se dirija a aquella plataforma que ofrezca las mejores cotizaciones *ask* o *bid* del mercado consolidado. Si ese mercado es IEX, la orden se vería afectada por el tope de velocidad. Chakrabarty, Huang y Jain (2022) muestran que el *speed bump* de IEX aumentó la latencia global del sistema, ralentizando a los operadores más rápidos del mercado. Más importante aún, encuentran que la liquidez experimentó mejoras significativas tras la conversión de IEX, lo que sugiere que el tope de velocidad fue especialmente dañino para las estrategias del HFT oportunista.

Budish *et al.* (2015) muestran teóricamente que, en el contexto de los mercados de alta frecuencia, el mercado continuo puede no ser un diseño óptimo al intensificar los costes de selección adversa de los proveedores de liquidez. En su lugar, proponen un sistema de negociación discreta, basado en subastas sucesivas y frecuentes (de muy corta duración) (*frequent batch auctions* o *FBA*). Para entender esta propuesta, considere un mercado continuo con N participantes, todos con idénticas latencias y que reaccionan a las mismas señales. Pueden elegir actuar como CM o como HFB. Supongamos que tras una señal informativa, el CM i tiene una orden en dinero en el libro. Inmediatamente, se dispara una carrera de velocidad entre el CM i y, potencialmente, $N-1$ HFB. Supongamos que los N mensajes llegan al mismo tiempo al servidor del mercado. En un mercado continuo, el *host* procesa los mensajes uno a uno en orden de llegada. Pero si llegan simultáneamente determina qué mensaje ejecutar primero de forma aleatoria. Esto significa que, en nuestro ejemplo, la probabilidad de que la orden del CM i se ejecute en dinero es de $(N-1)/N$. Ante un escenario tan desfavorable, el CM i compensará sus altos costes de selección adversa manteniendo un *spread* ancho. En cambio, en un mercado de negociación discreta, las órdenes se acumularían durante un determinado periodo de tiempo antes de casarlas, ralentizando *de facto* todas las órdenes y dando al CM i tiempo suficiente para revisar su orden incluso si es más lento que los HFB.

La teoría de Budish *et al.* (2015) predice que en un mercado continuo los costes de selección adversa serán mayores que en un mercado discreto y que, por tanto, la liquidez será menor. Indriawan, Shkillo y Pascual (2022) utilizan el cambio de mercado discreto (subastas cada cinco segundos) a mercado continuo del Taiwan Stock Exchange (TWSE) el 23 de marzo de 2020 para testar empíricamente las predicciones teóricas de Budish *et al.* (2015). Encuentran que, tras el cambio a mercado continuo, los costes de selección adversa en el TWSE efectivamente aumentaron, mientras que la liquidez disminuyó. El incremento en los costes de selección adversa fue mayor entre activos más líquidos, donde la presencia del HFT cabe esperar que sea mayor. También observan un aumento en el volumen negociado, causado por un mayor volumen tóxico, que asocian al arbitraje de baja latencia. Más volumen significa más beneficios para el mercado, por lo que éstos podrían ser reticentes a cambiar el *status quo*.

Comprobar empíricamente si estas propuestas pueden ser efectivas a la hora de reducir la intensidad de la carrera tecnológica es todo un reto, entre otras cosas, porque las inversiones en velocidad no son directamente observables. Existe, no obstante, evidencia derivada de la economía experimental, esto es, mercados simulados en entornos controlados. Por un lado, Aldrich y López Vargas (2020) encuentran que tras pasar de mercado continuo a FBA, los participantes en su experimento reducen su inversión en velocidad entre un 36 % y un 48 %. Por otro lado, Khapko y Zoican (2021) encuentran que los topes de velocidad asimétricos (aplicados sobre tomadores de liquidez solamente) reducen la inversión en velocidad en un 20 % y el efecto es mayor si aumentamos la magnitud del retraso.

6.2. Liquidez fantasma

Aunque los estudios existentes asocian mayor HFT con mejoras en indicadores estándar de liquidez, algunas voces críticas apuntan a diversos problemas que estos indicadores podrían no captar. Uno de ellos es la llamada liquidez fantasma (*ghost o phantom liquidity*). Considere que un HFT quiere comprar IBM. Para ello coloca una orden límite de compra en el NYSE y espera. Ahora bien, dado que IBM se negocia en otras 23 bolsas (ignoremos las *dark pools* por simplificar), el HFT está perdiendo la oportunidad de negociar si la orden de venta compatible llegase a otra plataforma. Así que, para maximizar sus posibilidades de ejecución, el HFT coloca órdenes de compra límite iguales en todas las plataformas de negociación. Cuando se ejecute una de ellas cancelará las demás. Imagine ahora un segundo operador, más lento, que introduce una orden de venta con el objetivo de tomar una de las órdenes límite colocadas por nuestro HFT. Al mismo tiempo, se ejecuta otra de las órdenes límite del HFT en otro mercado. Como la tecnología del HFT es más rápida, los mensajes de cancelación llegan antes al *host* que la orden de venta. Como consecuencia, la orden del vendedor o bien no se ejecuta o lo hace a un precio peor. Este ejemplo ilustra que, para un tomador de liquidez lento, la liquidez observada puede ser menor que la realmente accesible. Es una liquidez fantasma y la duplicación de órdenes, su principal causa.

La liquidez fantasma desaparece rápidamente del libro sin ser ejecutada. Por tanto, es una forma inestable de suministro de liquidez. Voces críticas con el HFT cuestionan que la mejora en liquidez atribuida al HFT sea real, sino más bien una ilusión de liquidez, ya que ésta únicamente existe para aquéllos que son lo suficientemente rápidos como para utilizarla. Esta liquidez ilusoria complica la evaluación de la situación del mercado y, también, el diseño de estrategias de negociación óptimas dirigidas a minimizar los costes de negociar o el impacto en precios.

Degryse, de Winne, Gresse y Payne (2020) estudian la liquidez fantasma en los mercados europeos. Encuentran que se trata de fenómeno económicamente significativo, siendo el causante de una parte importante de la actividad de cancelaciones de órdenes. Además, verifican que los HFT son los que más contribuyen a ella (seguidos de otros AT). No es sorprendente, por tanto, que se dé en mayor grado en valores con una mayor capitalización bursátil

y un mayor grado de fragmentación. El resultado probablemente más preocupante de este estudio es que la liquidez fantasma aumenta los costes efectivos de negociar de los operadores más lentos. La liquidez fantasma es, por tanto, un fenómeno no menor y que causa externalidades negativas sobre los operadores menos sofisticados.

6.3. HFT y riesgo sistémico

La liquidez cambia a lo largo del tiempo de forma no perfectamente predecible. Las crisis financieras de 1987 y de 2008-2009 o la crisis del COVID-19 de 2020 son ejemplos (sin duda, extremos) de la incertidumbre asociada a la liquidez futura tanto a nivel de mercado como a nivel de activos individuales (por ejemplo, Rösch y Kaserer, 2014; Beber y Pagano, 2013; Chakrabarty y Pascual, 2023). Esta incertidumbre asociada a la liquidez futura aumenta el riesgo sobre el valor de liquidación de cualquier inversión y, por tanto, sobre los rendimientos netos futuros. Este riesgo, se conoce como riesgo de liquidez.

Chordia, Roll y Subramanyam (2000) demuestran que la liquidez de activos individuales se mueve con la liquidez agregada del mercado. En otras palabras, la liquidez de activos individuales es función de un factor común, que es la liquidez del mercado. Llamamos a este fenómeno comunalidad en liquidez (*commonality in liquidity*). Debido a la existencia de ese factor común, el riesgo de liquidez no se puede eliminar a través de la diversificación. Por tanto, la comunalidad en liquidez es una fuente de riesgo sistemático, al igual que lo es la más conocida comunalidad en rentabilidad.

Sabemos que los movimientos comunes en rentabilidad reducen los beneficios de la diversificación. Los movimientos comunes en liquidez son igualmente indeseables, porque facilitan que *shocks* individuales en liquidez se propaguen rápidamente a todo el sistema, contribuyendo a desestabilizar el mercado. Al igual que los inversores aversos al riesgo exigen una prima por invertir en valores cuyos precios son más sensibles a los movimientos del mercado, también exigirán una prima por invertir en valores cuya liquidez muestre una covarianza mayor con la liquidez del mercado. Una mayor comunalidad en liquidez, por tanto, suma a la beta del activo y aumenta el coste de capital de la empresa (por ejemplo, Acharya y Pedersen, 2005).

Hemos visto que las empresas de HFT siguen estrategias comunes y que compiten entre ellas para explotar las mismas oportunidades de beneficio. Esto sugiere que sus algoritmos deben ser similares y responder a las mismas señales, por lo que la actividad de diferentes empresas de HFT tiene que estar mutuamente correlacionada. Diferentes estudios apoyan este supuesto, mostrando empíricamente que la actividad de las empresas de HFT experimenta una correlación mayor que la de otras empresas de inversión (por ejemplo, Chaboud *et al.*, 2014; Benos, Brugler, Hjalmarsson y Zikes, 2017). Esta comunalidad en la actividad

del HFT preocupa en tanto en cuanto pueda contribuir a aumentar el riesgo sistemático de inversor y, por tanto, tener efectos negativos sobre la inversión real y el crecimiento de las empresas²⁴.

Maceniece, Malceniaks y Putnins (2019) examinan esta cuestión aprovechando la entrada escalonada de la plataforma de negociación Chi-X en diversos mercados europeos entre 2007 y 2009. La entrada de Chi-X constituye un buen experimento natural porque provocó un aumento sustancial del HFT en Europa (Menkveld, 2013). Mediante contrastes estadísticos y econométricos, estos autores encuentran que mayor actividad del HFT se asocia con mayor comunalidad, tanto en rendimientos como en liquidez, y el impacto es económicamente significativo. El efecto sobre la comunalidad en rentabilidad se atribuye a las estrategias comunes entre empresas de HFT (Boehmer *et al.*, 2018) y a la mayor rapidez de ajuste de las cotizaciones de los HFT a la información general del mercado. El efecto sobre la comunalidad en liquidez se asocia a su intensiva actividad de seguimiento, a la correlación entre estrategias oportunistas que demandan liquidez, y a la tendencia de los HFMM a borrarse del mercado cuando las condiciones no les son favorables.

En general, el HFT tiene un efecto ambiguo sobre el coste del capital de las empresas y el nivel de inversión real en la economía. Por un lado, la actividad de creación de mercado por parte de los HFT aumenta el nivel medio de liquidez, es decir, disminuye los costes implícitos de negociar en los mercados. Por tanto, una mayor contribución de los HFMM a la provisión de liquidez debería reducir el coste de capital de las empresas a través de una menor prima por iliquidez (Amihud y Mendelson, 1986). Por otro lado, el HFT aumenta el riesgo sistemático y, por tanto, la beta de la empresa (Acharya y Pedersen, 2005). Cuál de estos efectos domina, es una cuestión que no ha recibido aún respuesta.

6.4. Fragilidad

Otro argumento común entre los críticos del HFT es su posible falta de compromiso a la hora de proporcionar liquidez y cómo esto puede aumentar la fragilidad del mercado. Recordemos, los HFMM son proveedores de liquidez endógenos (*ELP*), es decir, proporcionan liquidez voluntariamente, para beneficiarse de ello. No tienen la obligación de estar siempre presentes en el mercado o de proporcionar liquidez en contra de la tendencia dominante cuando hay fuertes desequilibrios de compra y venta. Existe el riesgo de que desaparezcan al unísono en momentos de alta tensión, cuando proporcionar liquidez es arriesgado, o cuando las oportunidades de beneficio son escasas, aumentando la fragilidad del mercado y contribuyendo a desestabilizarlo.

Esta preocupación es especialmente comprensible si se tiene en cuenta que estos *ELP* han desplazado a los *CM* tradicionales. Si los primeros abandonan el barco en tiempos de

²⁴ También preocupa que pueda contribuir a desestabilizar los mercados, como veremos en la sección 6.4.

tormenta, los segundos no cabe esperar que se pongan al timón en su ausencia, simplemente porque ya no les resulta rentable. No pueden cubrir sus pérdidas durante las tormentas con los beneficios que ya no obtienen en tiempos de calma. Además, las empresas de HFT, por lo general, están poco capitalizadas, lo que significa que están sujetas a riesgo de fallido²⁵. En épocas de estrés o en presencia de una perturbación significativa en los mercados, podría producirse una oleada de fallidos, que podría extenderse también a otras empresas, generando riesgo sistémico.

Annand y Venkataraman (2016) estudian si los ELP (HFMM) que operan en el Toronto Stock Exchange proporcionan liquidez de forma fiable. Al igual que Malceniece *et al.* (2019), encuentran que la oferta de liquidez de los diferentes ELP está fuerte y positivamente correlacionada, de forma que suele moverse de forma sincrónica (comunalidad). Así, la contribución global de los ELP a la liquidez de un activo concreto se mueve con su contribución global en todo el mercado. Además, la contribución de un ELP concreto en un activo dado se mueve con la contribución global de los ELP en dicho activo. Finalmente, la participación global de los ELP varía con las condiciones del mercado: aumenta con el volumen y la frecuencia de negociación (menores costes de gestión de inventario), pero disminuye durante periodos de fuertes desequilibrios entre compras y ventas (mayor riesgo de selección adversa). Esto sugiere que la fragilidad del mercado, impulsada por el comportamiento sincrónico de los HFMM, podría aumentar cuando las condiciones del mercado son desfavorables para la provisión de liquidez.

¿Contribuye el HFT a desestabilizar los mercados? La evidencia en este sentido es mixta. Kirikenko *et al.* (2017) encuentran que durante el *Flash Crash* del 6 de mayo de 2010, los HFMM no alteraron la dinámica de sus inventarios, a pesar de la fuerte caída de precios. Annand y Venkataraman (2016) observan que la participación de los HFT en la provisión de liquidez aumenta con la volatilidad (periodos de estrés), posiblemente porque mayor volatilidad se asocia a beneficios anormales en la creación de mercado. Chakrabarty y Pascual (2023) encuentran que tras el estallido de la crisis del COVID-19 los valores del S&P500 con mayor presencia del HFT no experimentaron una mayor reducción ni en la liquidez media ni en la competencia por la provisión de liquidez que aquellos activos con una menor participación del HFT, ni siquiera en aquellos sectores de actividad más afectados por la crisis. Frente a toda esta evidencia positiva, Brogaard *et al.* (2018) encuentran que, durante movimientos extremos en los precios de los activos individuales, los HFMM proporcionan liquidez al resto del mercado, pero este comportamiento cambia cuando se producen movimientos extremos de precios simultáneamente en varios activos. En general, la evidencia empírica existente debería aliviar el temor de algunos reguladores a que los HFMM pudieran retirarse en masa de la provisión de liquidez en tiempos de estrés.

²⁵ Como ejemplo, véase el caso de Knight Capital, el mayor operador en renta variable en EE. UU. en 2012, con una cuota de mercado del 17 %. El 1 de agosto de 2012, un error de código en un algoritmo provocó pérdidas multimillonarias a la empresa en sólo una hora de negociación, siendo absorbida por la empresa rival Getco LLC una semana después (<https://www.henricodolfing.com/2019/06/project-failure-case-study-knight-capital.html>).

6.5. Formación de precios a frecuencias bajas

La evidencia empírica sugiere que los HFT contribuyen significativamente al proceso de formación del precio, pero esas mejoras se han documentado para frecuencias muy altas. Las voces críticas con el HFT consideran estas mejoras en eficiencia irrelevantes, puesto que la mayoría de los inversores no tienen horizontes de inversión tan cortos y las decisiones corporativas no se toman con una frecuencia de milisegundos. La cuestión relevante debería ser si los HFT hacen más eficientes los precios en frecuencias que son importantes para los “humanos”.

Dos trabajos independientes han abordado esta cuestión recientemente. Por un lado, Chakrabarty, Moulton y Wang (2022) estudian si el HFT alivia el problema (humano) del déficit de atención. Varios estudios muestran que los operadores humanos se distraen fácilmente alrededor de anuncios de beneficios cuando muchas empresas anuncian sus beneficios simultáneamente (Hirshleifer, Lim y Teoh, 2009), cuando hay eventos deportivos importantes (Drake, Gee y Thornock, 2015) o cerca de festivos o fines de semana (Della Vigna y Pollet, 2009). Cuando esto ocurre, los precios de las acciones infrarreaccionan al contenido de los anuncios y, posteriormente, la información se incorpora a los precios gradualmente durante las siguientes semanas. Este fenómeno se conoce como *post earnings announcement drift* (PEAD). A menos que los algoritmos reflejen de algún modo los sesgos humanos de sus propios programadores, los algoritmos no deberían sufrir de déficit de atención. En línea con este argumento, el estudio encuentra que el HFT ayuda a paliar los efectos de la falta de atención en la formación de precios, tanto a corto como a largo plazo.

Por otro lado, Chordia y Miao (2020) analizan si los HFT facilitan la incorporación de información fundamental en los precios. Al igual que en el estudio anterior, se centran en los anuncios de beneficios. Utilizando *SRun* como medida indirecta de HFT (sección 3), analizan las rentabilidades anormales del día del anuncio y del día siguiente condicionadas a la magnitud de la sorpresa contenida en el anuncio y al nivel de actividad del HFT. También examinan el PEAD, definido como la rentabilidad anormal acumulada durante los 60 días siguientes al anuncio. Encuentran que la actividad del HFT mejora la eficiencia en precios. La reacción del mercado a la sorpresa contenida en el anuncio aumenta con la actividad del HFT y el PEAD disminuye, hasta el punto de ser no significativo cuando la participación del HFT es muy alta.

En general, estos estudios sugieren que el HFT no sólo contribuye a mejorar la eficiencia de los precios en las frecuencias ultra altas. También mejora la eficiencia en precios en horizontes que son relevantes para la toma de decisiones de inversores individuales y empresas.

6.6. Adquisición de información

Un operador informado contribuye a la formación del precio porque adquiere nueva información (señal privada) y negocia en base a ella. En cambio, cuando un HFT es el primero

en reaccionar a una señal proveniente del mercado de futuros, bien para tomar posiciones especulativas o bien para ajustar sus cotizaciones en el mercado de contado, está negociando con una señal pública. No obstante, al acelerar la incorporación de ésta en el precio de contado está contribuyendo al proceso de formación del precio. El HFT, por tanto, mejora la eficiencia con respecto a información existente, ya revelada.

Cuando el HFT utiliza algoritmos de *machine learning* para detectar actividad informada y negociar con ella (*back running*), la competencia del HFT acelera la incorporación de la información privada al precio. Observe, sin embargo, que el HFT está negociando con información adquirida por otros operadores (*free-riding*). Además, estos algoritmos de anticipación erosionan las rentas que los agentes informados pueden extraer de sus señales privadas (Yang y Zhu, 2020; Baldauf y Mollner, 2020). Si esta actividad del HFT es muy intensa y persistente, podría desalentar la adquisición de información por parte de los agentes informados. Puede darse, por tanto, la paradoja de que el HFT contribuye a la formación del precio respecto a la información disponible, al tiempo que la reduce con respecto a la información adquirible.

Cuadro 4.

Impacto del HFT sobre la calidad del mercado

<i>Dimensión</i>	<i>Conclusiones</i>	<i>Evidencia</i>
Liquidez	(a) Efecto positivo del HFT globalmente considerado.	(a) Hendershott, Jones y Menkveld (2011); Riordan y Storkenmaier (2012); Hasbrouck y Saar (2013); Boehmer, Fong y Wu (2020).
	(b) Efecto positivo del HFT creador de mercado (HFMM).	(b) Menkveld (2013); Brogaard <i>et al.</i> (2015); Brogaard y Garriott (2019).
	(c) Efecto negativo del HFT oportunista (HFB).	(c) Brogaard, Hendershott y Riordan (2017); Foucault, Kozhan, y Tham (2017); Shkilko y Sokolov (2020); Chakrabarty <i>et al.</i> (2021); Chakrabarty, Huang y Jain (2022); Indriawan, Shkilko y Pascual (2022).
	(d) El HFT contribuye a generar liquidez fantasma.	(d) Degryse <i>et al.</i> (2020).
	(e) EL HFT aumenta los movimientos comunes en liquidez.	(e) Chaboud <i>et al.</i> (2014); Benos <i>et al.</i> , 2017; Boehmer, Saar, and Wu (2018); Maceniece, Malceniaks y Putnins (2019).
	(f) La evidencia, por lo general, no apoya la hipótesis de que el HFT aumenta la fragilidad de los mercados.	(f) Annand y Venkataraman (2016); Kirikenko <i>et al.</i> (2017); Brogaard, Carrion, Moyaert, Riordan, Shkilko y Sokolov (2018); Chakrabarty y Pascual (2023).

Cuadro 4. (continuación)

Impacto del HFT sobre la calidad del mercado

Dimensión	Conclusiones	Evidencia
Eficiencia y formación del precio	(a) Efecto positivo del HFT globalmente considerado.	(a) Chaboud <i>et al.</i> (2014); Conrad, Wahal, y Xiang (2015); Hu, Pan y Wang (2017).
	(b) Efecto positivo del HFT creador de mercado (HFMM).	(b) Riordan y Storkenmaier (2012); Brogaard, Hendershott y Riordan (2019); Chakrabarty <i>et al.</i> (2022).
	(c) Efecto positivo del HFT oportunista (HFB).	(c) Brogaard, Hendershott y Riordan (2014; 2019).
	(d) Efecto positivo en la eficiencia incluso a frecuencias bajas.	(d) Chordia y Miao (2020); Chakrabarty, Moulton y Wang (2022).
	(e) El HFB desincentiva la adquisición de información.	(e) Weller (2018); Lee y Watts (2020).

Este cuadro resume las principales conclusiones de la literatura académica sobre el impacto del HFT en la calidad del mercado, y se citan los artículos más representativos en cada caso.

Weller (2018) estudia empíricamente esta hipótesis midiendo la adquisición de información alrededor de anuncios de beneficios en EE. UU. condicionada al nivel de actividad del HFT, que valora mediante medidas indirectas. Intuitivamente, cuanto más adquisición de información se produzca, más información se incorporará al precio antes del anuncio y menor será la reacción del mercado al propio anuncio. Si la competencia del HFT desincentiva la adquisición de información, mayor será la reacción del mercado al anuncio público. Weller encuentra que la incorporación de nueva información antes del anuncio cae con la actividad de HFT, incluso hasta un mes antes de la fecha del anuncio. Muestra, por tanto, una fuerte asociación negativa entre HFT y adquisición de información. En la misma línea, Lee y Watts (2020) encuentran que un *shock* negativo a la actividad del HFT se asocia a un incremento en la adquisición de información previa a anuncios de beneficios.

El cuadro 4 resume las principales conclusiones de la investigación sobre el impacto del HFT en la calidad del mercado.

7. CONCLUSIONES

Mediante la revisión de la investigación académica sobre negociación de alta frecuencia o HFT desde el año 2010 hasta la actualidad, este trabajo evalúa el impacto que el surgimiento de este nuevo tipo de participante ha tenido sobre la calidad de los mercados financieros, entendida en términos de mayor liquidez y eficiencia en precios.

Concluimos que el HFT globalmente considerado ha tenido un efecto neto positivo en la liquidez de los activos y mercados financieros. Este impacto se debe en gran medida a la estrategia canónica dominante en el HFT, la creación de mercado. Muchos HFT eligen

la estrategia de proporcionar liquidez voluntariamente, actuando como creadores de mercado endógenos, para generar beneficios. Estos HFMM utilizan tecnología y servicios de baja latencia, una activa gestión del riesgo –a través del intensivo monitoreo de sus órdenes– y una actividad simultánea en varios mercados para conseguir ventajas competitivas frente a otros creadores de mercado en forma de menores costes operativos, de selección adversa y de gestión de inventario. En un entorno altamente competitivo, los HFMM trasladan esa ventaja en costes a sus clientes en forma de menores primas y descuentos por negociar, aumentando la liquidez.

No obstante, además de crear mercado, los HFT también implementan estrategias oportunistas como el arbitraje de baja latencia, la especulación direccional y el *news trading*. Todas estas estrategias imponen una externalidad negativa sobre los proveedores de liquidez relativamente más lentos en forma de mayores costes de selección adversa. La investigación teórica predice, y la empírica corrobora, que mayor presencia del HFT oportunista se asocia con un menor nivel de liquidez.

Los detractores del HFT apuntan a potenciales efectos negativos del HFT que las medidas estándar de liquidez difícilmente pueden capturar. Por un lado, parte de la liquidez proporcionada por los HFT se evapora rápidamente, sin que pueda ser aprovechada por aquellos operadores relativamente más lentos. La evidencia existente indica que esta liquidez fantasma es un fenómeno económicamente significativo y una fuente de externalidades negativas sobre operadores menos sofisticados. Por otro lado, el HFT aumenta la comunalidad en rentabilidades y liquidez, lo que conlleva menores beneficios por diversificar y un mayor riesgo sistemático. Si el aumento del riesgo sistemático superase los beneficios derivados de los menores costes de negociar (menores primas por iliquidez), el HFT podría traer consigo un aumento del coste de oportunidad de las empresas y, como consecuencia, un efecto negativo sobre la inversión real en la economía. Finalmente, depender de los HFT para proveer liquidez podría aumentar la fragilidad del mercado, ya que estos proveedores de liquidez endógenos podrían desaparecer al unísono cuando el riesgo de proporcionar liquidez sea anormalmente alto o los beneficios anormalmente bajos. La evidencia existente apunta, sin embargo, a que este temor es infundado.

Concluimos también que, tanto el HFT globalmente considerado como los HFMM y los HFT oportunistas por separado, contribuyen a hacer los precios más eficientes. Los HFMM actualizan sus cotizaciones rápidamente ante cualquier señal informativa. Los HFT oportunistas negocian en la dirección de cambios permanentes en los precios a muy corto plazo o reducen el ruido en precios negociando en contra de desviaciones temporales respecto al valor de consenso. Como resultado, tanto los cambios en sus cotizaciones como las transacciones iniciadas por los HFT contribuyen significativamente a la formación del precio. Voces críticas con el HFT cuestionan la relevancia de estas mejoras en eficiencia por darse a frecuencias muy altas, a las que ni las empresas ni los operadores humanos toman decisiones. Sin embargo, estudios recientes sugieren que el HFT podría también ayudar a mejorar la eficiencia en horizontes que son relevantes para inversores y empresas. Otros señalan que mientras que el HFT, globalmente considerado, mejora la eficiencia en precios respecto a la

información existente (pública o privada), el HFT oportunista, mediante estrategias como el *back running*, podría desincentivar la adquisición de nueva información, lo que podría afectar a la eficiencia en precios a medio y largo plazo. La evidencia empírica existente apoya este argumento.

Tras años de mejorar la tecnología del mercado para adaptarla a las necesidades de la negociación algorítmica, algunos mercados están empezando a buscar formas de ralentizar el proceso de negociación con el fin de nivelar el campo de juego en cuanto a velocidad se refiere y frenar la carrera tecnológica en latencia. Algunas propuestas suponen variaciones mínimas sobre la microestructura de los mercados y son fáciles de implementar, como imponer retrasos intencionados y sistemáticos en el tiempo de procesamiento de órdenes. Otras opciones, sin embargo, suponen cambios drásticos y complejos, como sustituir la negociación continua por subastas de alta frecuencia. Estos cambios podrían encontrar la resistencia de los propios mercados, que podrían priorizar sus propios intereses (mayor volumen, mayores beneficios en mercados continuos) sobre los de los participantes en la negociación (menores costes de crear mercado, mayor liquidez, mayor bienestar en subastas de alta frecuencia).

Este trabajo muestra que bajo la etiqueta del HFT se incluyen múltiples estrategias y que, a la hora de evaluar su impacto sobre la calidad del mercado, es conveniente considerarlas de forma independiente. Del mismo modo, cualquier iniciativa dirigida a restringir la actividad del HFT o a eliminar las jerarquías en velocidad, debería diseñarse y evaluarse cuidadosamente en el contexto de las diferentes estrategias del HFT. Una iniciativa mal orientada podría tener efectos contrarios a los deseados sobre la calidad del mercado. Cualquier política dirigida a estimular los efectos positivos del HFT y reducir sus costes amplificaría el beneficio neto del HFT sobre la calidad de los mercados que, tras esta revisión de la literatura, se antoja mayormente positivo.

Con la consolidación de la industria del HFT y tras constatar que el HFT dista de la imagen perversa que retrata el *bestseller* de Michael Lewis, la negociación algorítmica ha dejado de copar los titulares de la prensa especializada. El mundo académico poco a poco va también desviando su atención del HFT hacia otros temas de mayor actualidad. Y es que muchas de las cuestiones inicialmente planteadas a raíz de la eclosión del HFT parecen haber recibido ya una respuesta satisfactoria. Por tanto, cabe esperar cierta desaceleración en el ritmo de producción de nuevos estudios académicos sobre HFT. No obstante, otras muchas cuestiones, no menores, algunas señaladas en este trabajo, se han tratado de manera tangencial y pueden dar fruto a nuevos proyectos de investigación que enriquezcan nuestro conocimiento sobre estos operadores amantes de la velocidad. Habrá que estar atentos.

Referencias

- ABAD, D., MASSOT, M., NAWN, S., PASCUAL, R. y YAGÜE, J. (2022). Message traffic and short-term illiquidity in High-Speed Markets. *SSRN Electronic Journal*.

- ABAD, D. y PASCUAL, R. (2010). Switching to a temporary call auction in times of high uncertainty. *Journal of Financial Research*, 33(1), pp. 45–75.
- ACHARYA, V. V. y PEDERSEN, L. H. (2005). Asset pricing with liquidity risk. *Journal of Financial Economics*, 77(2), pp. 375–410.
- AIT-SAHALIA, Y. y SAGLAM, M. (2017). High Frequency Market Making: Implications for Liquidity. *SSRN Electronic Journal*.
- ALDRICH, E. M. y LÓPEZ VARGAS, K. (2020). Experiments in high-frequency trading: comparing two market institutions. *Experimental Economics*, 23(2), pp. 322–352.
- ALDRIDGE, I. (2009). *High-frequency trading: A practical guide to algorithmic strategies and trading systems*. Wiley.
- AMIHUD, Y. y MENDELSON, H. (1986). Asset pricing and the bid-ask spread. *Journal of Financial Economics*, 17(2), pp. 223–249.
- AMIHUD, Y., MENDELSON, H. y PEDERSEN, L. H. (2013). *Market Liquidity*. Cambridge Books.
- ANAND, A. y VENKATARAMAN, K. (2016). Market conditions, fragility, and the economics of market making. *Journal of Financial Economics*, 121(2), pp. 327–349.
- ANGEL, J. J., HARRIS, L. E. y SPATT, C. S. (2015). Equity trading in the 21st Century: An update. *Quarterly Journal of Finance*, 5(1), pp. 1–39.
- AQUILINA, M., BUDISH, E. y O'NEILL, P. (2022). Quantifying the high-frequency trading “arms race”. *The Quarterly Journal of Economics*, 137(1), pp. 493–564.
- BALDAUF, M. y MOLLNER, J. (2020). High-Frequency Trading and Market Performance. *Journal of Finance*, 75(3), pp. 1495–1526.
- BARON, M., BROGAARD, J., HAGSTRÖMER, B. y KIRILENKO, A. (2019). Risk and Return in High-Frequency Trading. *Journal of Financial and Quantitative Analysis*, 54(3), pp. 993–1024.
- BARTLETT, R. P. y MCCRARY, J. (2015). Trying to force the SEC's hand on high-speed trading. *The New York Times*, 18 de diciembre.
- BARTLETT, R. P. y MCCRARY, J. (2019). How rigged are stock markets? Evidence from micro-second timestamps. *Journal of Financial Markets*, 45, pp. 37–60.
- BEBER, A. y PAGANO, M. (2013). Short-Selling Bans Around the World: Evidence from the 2007-09 Crisis. *Journal of Finance*, 68(1), pp. 343–381.
- BENOS, E., BRUGLER, J., HJALMARSSON, E. y ZIKES, F. (2017). Interactions among High-Frequency Traders. *Journal of Financial and Quantitative Analysis*, 52(4), pp. 1375–1402.
- BESSEMBINDER, H., PANAYIDES, M. y VENKATARAMAN, K. (2009). Hidden liquidity: An analysis of order exposure strategies in electronic stock markets. *Journal of Financial Economics*, 94(3), pp. 361–383.
- BHATTACHARYA, A. y SAAR, G. (2021). Limit Order Markets under Asymmetric Information. *SSRN Electronic Journal*.
- BIAIS, B. y FOUCAULT, T. (2014). HFT and market quality. Bankers. *Markets and Investors*, 128, pp. 5–19.
- BIAIS, B., FOUCAULT, T. y MOINAS, S. (2015). Equilibrium fast trading. *Journal of Financial Economics*, 116(2), pp. 292–313.
- BIAIS B. y WOOLLEY P. (2011). *High frequency trading*. Toulouse University.
- BOEHMER, E., FONG, K. y WU, J. J. (2021). Algorithmic trading and market quality: International evidence. *Journal of Financial and Quantitative Analysis*, 56(8), pp. 2659–2688.
- BOEHMER, E., LI, D. y SAAR, G. (2018). The competitive landscape of high-frequency trading firms. *Review of Financial Studies*, 31(6), pp. 2227–2276.

- BOEHMER, E., SAAR, G. y YU, L. (2005). Lifting the veil: an analysis of pre-trade transparency at the NYSE. *Journal of Finance*, 60, pp.783–815.
- BONGAERTS, D. y VAN ACHTER, M. (2021). Competition among liquidity providers with access to high-frequency trading technology. *Journal of Financial Economics*, 140(1), pp. 220–249.
- BOWLEY, G. (2010). Computers that trade on the news. *The New York Times*, 22 de diciembre.
- BOWLEY, G. (2011). The new speed of money, reshaping markets. *The New York Times*, 1 de enero.
- BROGAARD, J., CARRION A., MOYAERT, T., RIORDAN, R., SHKILKO, A. y SOKOLOV, K. (2018). High frequency trading and extreme price movements. *Journal of Financial Economics*, 128(2), pp. 253–265.
- BROGAARD, J. y GARRIOTT, C. (2019). High-Frequency Trading Competition. *Journal of Financial and Quantitative Analysis*, 54(4), pp. 1469–1497.
- BROGAARD, J., HAGSTRÖMER, B., NORDÉN, L. y RIORDAN R. (2015). Trading Fast and Slow: Colocation and Liquidity. *Review of Financial Studies*, 28(12), pp. 3407–3443.
- BROGAARD, J., HENDERSHOTT, T. y RIORDAN, R. (2014). High-frequency trading and price discovery. *Review of Financial Studies*, 27(8), pp. 2267–2306.
- BROGAARD, J., HENDERSHOTT, T. y RIORDAN, R. (2017). High frequency trading and the 2008 short-sale ban. *Journal of Financial Economics*. 124(1), pp. 22–42.
- BROGAARD, J., HENDERSHOTT, T. y RIORDAN, R. (2019). Price Discovery without Trading: Evidence from Limit Orders. *Journal of Finance*, 74(4), pp. 1621–1658.
- BROLLEY, M. y MALINOVA, K. (2021). Informed liquidity provision in a limit order market. *Journal of Financial Markets*, 52, 100566.
- BUDISH, E., CRAMPTON, P. y SHIM, J. (2015). The high frequency trading arms race: frequent batch auctions as a market design response. *The Quarterly Journal of Economics*, 130 (November), pp. 1547–1621.
- CARTEA, A., JAIMUNGAL, S. y PENALVA, J. (2015). *Algorithmic and High-Frequency Trading*. Cambridge University Press.
- CARTEA, Á., PAYNE, R., PENALVA, J. y TAPIA, M. (2019). Ultra-fast activity and intraday market quality. *Journal of Banking & Finance*, 99, pp. 157–181.
- CHABOUD, A. P., CHIQUOINE, B., HJALMARSSON, E. y VEGA, C. (2014). Rise of the machines: Algorithmic trading in the foreign exchange market. *The Journal of Finance*, 69(5), pp. 2045–2084.
- CHAKRABARTY, B., COMERTON-FORDE, C. y PASCUAL, R. (2022). Identifying HFT activity without proprietary data. *SSRN Electronic Journal*.
- CHAKRABARTY, B., JAIN, P. K., SHKILKO, A. y SOKOLOV, K. (2021). Unfiltered market access and liquidity: Evidence from the SEC Rule 15c3-5. *Management Science*, 67, pp. 1183–1198.
- CHAKRABARTY, B., HENDERSHOTT, T., NAWN, S. y PASCUAL, R. (2022). Order exposure in high-frequency markets. *SSRN Electronic Journal*.
- CHAKRABARTY, B., HUANG, J. y JAIN, P. K. (2022). Effects of Leveled Speed on Market Quality and Exchange Competition. *SSRN Electronic Journal*.
- CHAKRABARTY, B., MOULTON, P. C. y PASCUAL, R. (2017). Trading system upgrades and short-sale bans: Uncoupling the effects of technology and regulation. *Journal of Empirical Finance*, 43(May), pp. 74–90.
- CHAKRABARTY, B., MOULTON, P. C. y WANG, X. (2022). Attention: How high-frequency trading improves price efficiency following earnings announcements. *Journal of Financial Markets*, 57(November), 100690.
- CHAKRABARTY, B. y PASCUAL, R. (2023). Stock liquidity and algorithmic market making during the COVID-19 crisis. *Journal of Banking & Finance*, 106415.

- CHORDIA, T., GREEN, T. C. y KOTTIMUKKALUR, B. (2018). Rent seeking by low-latency traders: Evidence from trading on macroeconomic announcements. *Review of Financial Studies*, 31(12), pp. 4650–4687.
- CHORDIA, T. y MIAO, B. (2020). Market efficiency in real time: Evidence from low latency activity around earnings announcements. *Journal of Accounting and Economics*, 70(2–3), 101335.
- CHORDIA, T., ROLL, R. y SUBRAHMANYAM, A. (2000). Commonality in liquidity. *Journal of Financial Economics*, 56(1), pp. 3–28.
- COCHRANE, J. H. (2013). Finance: function matters, not size. *Journal of Economic Perspectives*, 27(2), pp. 29–50.
- COMERTON-FORDE, C. y PUTNINS, T. J. (2015). Dark trading and price discovery. *Journal of Financial Economics*, 118, pp. 70–92.
- CONRAD, J., WAHAL, S. y XIANG, J. (2015). High-frequency quoting, trading, and the efficiency of prices. *Journal of Financial Economics*, 116(2), pp. 271–291.
- DEGRYSE, H., DE WINNE R., GRESSE, C. y PAYNE, R. (2020). Cross-venue liquidity provision: High frequency trading and ghost liquidity. *SSRN Electronic Journal*.
- DELLAVIGNA, S. y POLLET, J. (2009). Investor inattention and Friday earnings announcements. *The Journal of Finance*, 64(2), pp. 709–749.
- DING, S., HANNA, J. y HENDERSHOTT, T. (2014). How slow is the NBBO? A comparison with direct exchange feeds. *Financial Review*, 49, pp. 313–332.
- DRAKE, M., ROULSTONE, D. y THORNOCK, J. (2015). The determinants and consequences of information acquisition via EDGAR. *Contemporaneous Accounting Research*, 32, pp. 1128–61.
- DUGAST, J. y FOUCAULT, T. (2018). Data abundance and asset price informativeness. *Journal of Financial Economics*, 130(2), pp. 367–391.
- DUHIGG, C. (2009). Stock traders find speed pays, in milliseconds. *The New York Times*, 23 de julio.
- EASLEY, D., LÓPEZ DE PRADO, M. y O'HARA, M. (2013). High Frequency Trading. Risk Books.
- EGGINTON, J. F., VAN NESS, B. F. y VAN NESS, R. A. (2016). Quote Stuffing. *Financial Management*, 45(3), pp. 583–608.
- EUROPEAN SECURITIES AND MARKET AUTHORITY (ESMA). (2014). High-frequency trading activity in EU equity markets. *Economic Report*, No. 1. (<https://www.esma.europa.eu>).
- FOUCAULT, T. (2013). Algorithmic trading: Issues and preliminary evidence. En F. ABERGEL, J. BOUCHAUD, T. FOUCAULT, C. LEHALLE y M. ROSENBAUM, *Market Microstructure: Confronting Many Viewpoints* (pp. 1–40). Wiley.
- FOUCAULT, T., HOMBERT, J. y ROŞU, I. (2016). News trading and speed. *Journal of Finance*, 71(1), pp. 335–382.
- FOUCAULT, T., KADAN, O. y KANDEL, E. (2013). Liquidity cycles and make/take fees in electronic markets. *The Journal of Finance*, 68(1), pp. 299–341.
- FOUCAULT, T., KOZHAN, R. y THAM, W. W. (2017). Toxic Arbitrage. *The Review of Financial Studies*, 30(4), pp. 1053–1094.
- FOUCAULT, T., PAGANO, M. y RÖELL, A. (2007). *Market Liquidity: Theory, Evidence and Policy*. Oxford University Press.
- FRIEDERICH, S. y PAYNE, R. (2015). Order-to-trade ratios and market liquidity. *Journal of Banking and Finance*, 50, pp. 214–223.
- FRINO, A., MOLLICA, V. y WEBB, R. I. (2014). The impact of co-location of securities exchanges' and traders' computer servers on market liquidity. *Journal of Futures Markets*, 34(1), pp. 20–33.
- GARVEY, R. y WU, F. (2010). Speed, distance, and electronic trading: New evidence on why location matters. *Journal of Financial Markets*, 13(4), pp. 367–396.

- GLOSTEN, L. R. y MILGROM, P. R. (1985). Bid, ask, and transaction prices in a specialist market with heterogeneously informed traders. *Journal of Financial Economics*, 14, pp. 71–100
- GOLDSTEIN, M. A., HU, G. y MENG, J. G. (2009). An analysis of liquidity across markets: Execution costs on the NYSE versus electronic markets. En J. MORREY y A. GUYTON (eds.), *Liquidity, Interest Rates and Banking (Financial Institutions and Services)*, capítulo 3. New York: Nova Publishers.
- GOLDSTEIN, M. A., KUMAR, P. y GRAVES, F. C. (2014). Computerized and high-frequency trading. *Financial Review*, 49(2), pp. 177–202.
- HASBROUCK, J. (1995). One security, many markets: Determining the contributions to price discovery. *The Journal of Finance*, 50, pp. 1175–1199.
- HASBROUCK, J. (2018). High-Frequency Quoting: Short-Term Volatility in Bids and Offers. *Journal of Financial and Quantitative Analysis*, 53(2), pp. 613–641.
- HASBROUCK, J. (2021). Price Discovery in High Resolution. *Journal of Financial Econometrics*, 19(3), pp. 395–430.
- HASBROUCK, J. y SAAR, G. (2009). Technology and liquidity provision: The blurring of traditional definitions. *Journal of Financial Markets*, 12, pp. 143–172.
- HASBROUCK, J. y SAAR, G. (2013). Low-latency trading. *Journal of Financial Markets*, 16(4), pp. 646–679.
- HARRIS, L. y HASBROUCK, J. (1996). Market vs. limit orders: The SuperDOT evidence on order submission strategy. *Journal of Financial and Quantitative Analysis*, 31, pp. 213–231.
- HENDERSHOTT, T., JONES, C. M. y MENKVELD, A. J. (2011). Does Algorithmic Trading Improve Liquidity? *The Journal of Finance*, 46(1), pp. 1–34.
- HENDERSHOTT, T. y MENKVELD, A. J. (2014). Price pressures. *Journal of Financial Economics*, 114, pp. 405–423.
- HENDERSHOTT, T. y MOULTON, P. C. (2011). Automation, speed, and stock market quality: The NYSE's Hybrid. *Journal of Financial Markets*, 14(4), pp. 568–604.
- HENDERSHOTT, T. y RIORDAN, R. (2013). Algorithmic trading and the market for liquidity. *Journal of Financial and Quantitative Analysis*, 48(4), pp. 1001–1024.
- HIRSCHEY, N. (2021). Do high-frequency traders anticipate buying and selling pressure? *Management Science*, 67(6), pp. 3321–3345.
- HIRSHLEIFER, D., LIM, S. y TEOH, S. H. (2009). Driven to distraction: extraneous events and underreaction to earnings news. *The Journal of Finance*, 64(5), pp. 2289–2325.
- HO, T. S. y STOLL, R. (1983). The dynamics of dealer markets under competition. *The Journal of Finance*, 38(4), pp. 1053–1074.
- HOFFMANN, P. (2014). A dynamic limit order market with fast and slow traders. *Journal of Financial Economics*, 113(1), pp. 156–169.
- HONG KONG INSTITUTE FOR MONETARY AND FINANCIAL RESEARCH (HKIMR). (2021). Algorithmic and high-frequency trading in Hong Kong's equity market: Adoption, market impact and risk management. *Applied Research Report*, No.1/2021.
- HU, G. C., PAN, J. y WANG, J. (2017). Early peek advantage? Efficient price discovery with tiered information disclosure. *Journal of Financial Economics*, 126, pp. 399–421.
- HULL, J. C. (2021). *Options, Futures, and other Derivatives*. Pearson.
- INDRIAWAN, I., PASCUAL, R. y SHKILKO, A. (2022). On the effects of continuous trading. *SSRN Electronic Journal*.
- JAIN, P. K. (2005). Financial market design and equity premium: Electronic versus floor trading. *The Journal of Finance*, 40(6), pp. 2955–2985.

- JOHNSON, B. (2010). *Algorithmic trading and DMA: An introduction to direct access trading strategies*. 4Myeloma Press.
- JOVANOVIC, B. y MENKVELD, A. J. (2016). Middlemen in Limit Order Markets. *SSRN Electronic Library*.
- JØRGENSEN, K., SKJELTORP, J. y ØDEGAARD, B. A. (2018). Throttling hyperactive robots – Order-to-trade ratios at the Oslo Stock Exchange. *Journal of Financial Markets*, 37, pp. 1–16.
- KHAPKO, M. y ZOICAN, M. (2021). Do speed bumps curb low-latency investment? Evidence from a laboratory market. *Journal of Financial Markets*, 55, 100601.
- KHOMYN, M. y PUTNINS, Š, T. J. (2021). Algos gone wild: What drives the extreme order cancellation rates in modern markets? *Journal of Banking and Finance*, 129, pp. 1-16.
- KIRILENKO, A., KYLE, A., SAMADI, M. y TUZUM, T. (2017). The Flash Crash: High-frequency trading in an electronic market. *The Journal of Finance*, 72(3), pp. 967–998.
- KOVAC, P. (2014). *Flash Boys: Not So Fast: An Insider's Perspective on High-Frequency Trading*. Directissima Press.
- KWAN, A., PHILIP, R. y SHKILKO, A. (2020). The Conduits of Price Discovery: A Machine Learning Approach. *SSRN Electronic Journal*.
- LAUGHLIN, G., AGUIRRE, A. y GRUNDFEST, J. (2014). Information transmission between financial markets in Chicago and New York. *Financial Review*, 49, pp. 283-312.
- LEE, C. M. C. y WATTS, E. M. (2021). Tick size tolls: Can a trading slowdown improve earnings news discovery? *Accounting Review*, 96(3), pp. 373–401.
- LEWIS, M. (2014). *Flash boys: A Wall Street Revolt*. Norton & Company.
- LIU, W. (2009). Monitoring and limit order submission risks. *Journal of Financial Markets*, 12(1), pp. 107-141.
- MALCENIECE, L., MALCENIEKS, K. y PUTNINS, Š, T. J. (2019). High frequency trading and comovement in financial markets. *Journal of Financial Economics*, 134(2), pp. 381–399.
- MALINOVA, K., PARK, A. y RIORDAN, R. (2018). Do Retail Investors Suffer from High Frequency Traders? *SSRN Electronic Journal*.
- MENKVELD, A. J. (2013). High frequency trading and the new market makers. *Journal of Financial Markets*, 16(4), pp. 712–740.
- MENKVELD, A. J. (2016). The Economics of High-Frequency Trading: Taking Stock. *Annual Review of Financial Economics*, 8, pp. 1–24.
- NARANG, R. (2013). *Inside the black box: A simple guide to quantitative and high frequency trading*. Wiley.
- O'HARA, M. (1995). *Market Microstructure Theory*. Blackwell.
- O'HARA, M. (2015). High frequency market microstructure. *Journal of Financial Economics*, 116(2), pp. 257–270.
- PARDO, A. y PASCUAL, R. (2012). On the hidden side of liquidity. *The European Journal of Finance*, 18(10), pp. 949–967.
- PATTERSON, S. (2012). *Dark pools: The rise of A.I. trading machines and the looming threat to Wall Street*. Cornerstone Digital.
- POPPER, G. (2012). On Wall Street, the rising cost of faster trades. *The New York Times*, 13 de agosto.
- RIORDAN, R. y STORKENMAIER, A. (2012). Latency, liquidity and price discovery. *Journal of Financial Markets*, 15(4), pp. 416–437.
- RÖSCH, C.G. y KASERER, C. (2014). Reprint of: Market liquidity in the financial crisis: The role of liquidity commonality and flight-to-quality. *Journal of Banking & Finance*, 45(1), pp. 152–170.
- SECURITIES EXCHANGE COMMISSION (SEC). (2010). Concept release on equity market structure. (<https://www.sec.gov/rules/concept/2010/34-61358.pdf>).

- SECURITIES EXCHANGE COMMISSION (SEC). (2014). Equity market structure literature review. Part II: High frequency trading (<http://www.sec.gov/marketstructure/research>).
- SHKILKO, A. y SOKOLOV, K. (2020). Every cloud has a silver lining: Fast trading, microwave connectivity, and trading costs. *The Journal of Finance*, 75(6), pp. 2899–2927.
- SOFIANOS, G. y WERNER, I. (2000). The trades of NYSE floor brokers. *Journal of Financial Markets*, 3, pp. 139–176.
- SUBRAHMANYAM, A. y ZHENG, H. (2016). Limit order placement by high-frequency traders. *Borsa Istanbul Review*, 16(4), pp. 185–209.
- VAN KERVEL, V. (2015). Competition for Order Flow with Fast and Slow Traders. *Review of Financial Studies*, 28(7), pp. 2094–2127.
- WELLER, B. M. (2018). Does Algorithmic Trading Reduce Information Acquisition? *The Review of Financial Studies*, 31(6), pp. 2184–2226.
- YANG, L. y ZHU, H. (2020). Back-Running: Seeking and Hiding Fundamental Information in Order Flows. *The Review of Financial Studies*, 33(4), pp. 1484–1533.

CAPÍTULO III

Aprendizaje automático en modelos de concesión de crédito: oportunidades y riesgos

Andres Alonso-Robisco
Jose Manuel Carbo

En el presente capítulo analizamos las oportunidades y riesgos que supone la aplicación de modelos de aprendizaje automático (*ML*, por sus siglas en inglés) en la concesión de crédito. Para ello realizamos una revisión guiada de la literatura, y acompañamos la discusión con la realización de un ejercicio empírico con una base de datos de libre acceso. Por un lado, la mayor capacidad de predicción de *ML* puede suponer un impacto económico, tanto por la provisión de nuevo negocio, como por el ahorro en capital regulatorio que una entidad financiera podría obtener si adoptara *ML* en sus modelos internos. El mayor rendimiento predictivo de *ML* también puede conllevar efectos positivos en la inclusión financiera, aunque estos resultados deben ser valorados junto con nuevos riesgos que vendrían de la mano de esta tecnología, como son especialmente la discriminación (sesgos) entre clases sociales, o la explicabilidad de los resultados, la cual analizaremos usando nuevas técnicas de interpretabilidad. Concluimos con una reflexión sobre la necesidad de lograr una satisfactoria explicabilidad de los modelos como condición necesaria para la puesta en producción de esta tecnología financiera, dando confianza a los usuarios de sistemas automatizados de concesión de crédito.

Palabras clave: machine learning, aprendizaje automático, credit scoring, explicabilidad.

1. INTRODUCCIÓN

El uso de modelos de aprendizaje automático o *machine learning* (ML) está ganando terreno en finanzas (Alonso-Robisco & Carbo, 2022c; Fernández, 2019; Gimeno y Sevillano, 2022) impulsado en gran medida por la suma de dos factores. En primer lugar, por el acceso a grandes conjuntos de datos (caracterizados por volumen, variedad, y variabilidad), los cuales requieren una tecnología escalable para su almacenamiento eficiente, tratamiento y posterior análisis. En segundo lugar, por los avances en computación en la nube y el uso de nuevas técnicas de modelización estadística como la inteligencia artificial (IA), de la que podemos considerar el ML como un subconjunto. En concreto, es a partir de la década de los ochenta cuando se populariza este tipo de modelos, permitiendo que los ordenadores aprendan automáticamente de los datos sin instrucciones directas de un ser humano, simulando un comportamiento inteligente (Estévez, 2022). Al igual que los modelos de econometría tradicional, el objetivo principal del ML es extraer información de los datos y hacer predicciones, si bien la gran diferencia entre ambos paradigmas de modelización estadística es que el uso de ML permite tratar el proceso que gobierna los datos como desconocido (Breiman, 2001). El énfasis, por tanto, no reside en modelos teóricos que describen el comportamiento supuesto de las variables, dejándose dicha tarea a complejos algoritmos que aprenden iterativamente el patrón que describen los datos.

Este cambio en el paradigma presenta oportunidades y riesgos a la hora de su implementación en un entorno financiero. Existe una extensa literatura académica que respalda el potencial de esta tecnología para resolver un elevado número de problemas dentro de la gestión del riesgo de crédito (Goodell *et al.*, 2001; Königstorfer y Thalmann, 2020), como por ejemplo la predicción de impagos, el establecimiento de sistemas de alerta temprana, o la prevención del fraude e identificación de comportamientos anómalos. En concreto, recientes encuestas identifican que una de las áreas donde más interés existe por parte de las entidades financieras para el uso de ML es en la concesión de préstamos (Institute of International Finance, 2019; Jung *et al.*, 2019). Precisamente, la posibilidad de sumar registros comportamentales de los clientes (por ejemplo, a través de la huella digital) hace de esta actividad un entorno ideal para un buen rendimiento de los modelos de ML: alta dimensionalidad de los datos y relaciones no lineales entre las variables que describen el comportamiento de los individuos (Berg *et al.*, 2020).

En este contexto, las autoridades y supervisores financieros han identificado el uso del ML como un área con gran potencial para la innovación financiera, incluyéndolo dentro de su ámbito de seguimiento (Alonso-Robisco & Carbo, 2022c; Gimeno y Sevillano, 2022). De hecho, podemos destacar iniciativas de experimentación desarrolladas en el BIS Innovation Hub como el proyecto [Ellipse](#), el cual trata de combinar fuentes de información estructurada y no estructurada con datos regulatorios existentes para mejorar la información sobre los riesgos sistémicos.

Sin embargo, el elevado potencial de esta tecnología no está exento de riesgos. Son numerosas las referencias académicas (Blattner, Nelson y Spiess, 2021; Tyagi, 2022) y super-

visoras (BAFIN, 2022; EBA, 2021; Dupont, Fliche y Yang, 2020; Institute of International Finance, 2018) que describen nuevos factores de riesgo asociados a esta tecnología que suscitan preocupación. Los modelos de *ML* son cada vez más complejos, y su naturaleza de “caja negra” les confiere un riesgo de modelo inherentemente nuevo (Alonso-Robisco & Carbo, 2022a) en particular en el campo de la concesión de crédito, debido a las necesidades de explicabilidad de los resultados, y al control de los posibles sesgos o discriminación. En este sentido, el enfoque regulador trata de evaluar el riesgo asociado al uso de sistemas basados en IA a través de la evaluación del potencial impacto negativo para los usuarios de los mismos. Así, bajo la pionera Directiva de Inteligencia Artificial propuesta por la Comisión Europa (legislación conocida como *AI Act*) un recomendador automático de productos de inversión o un *chatbot* para la interacción con los clientes no tendría tanto impacto potencial negativo como un sistema de evaluación de riesgo crediticio (*credit scoring*), cuyas potenciales decisiones de denegación de un préstamo pueden dañar la solvencia de empresas e individuos. En este último caso se establece como prioritario la gestión del riesgo de modelo, y el buen gobierno de la tecnología, existiendo el requerimiento de cumplir con un test de conformidad regulatorio (Floridi *et al.*, 2022).

Dado el elevado potencial de esta tecnología para mejorar la capacidad de predicción, así como su incipiente uso por parte de la industria financiera, y atención captada por los supervisores financieros, en este capítulo repasamos el estado actual de la investigación sobre el diseño e implementación de sistemas automáticos de evaluación y concesión de crédito basados en *ML*, realizando una revisión guiada de la literatura académica, unido a un ejercicio empírico con una base de datos de crédito de libre acceso en <https://www.kaggle.com>. La sección 2 comienza analizando las principales ventajas derivadas de su uso, a saber la mejor capacidad de predicción de impagos, y su potencial para una mayor inclusión financiera. Posteriormente, en la sección 3 se revisan las consecuencias no intencionadas del uso de *ML*, en particular centrándose en los problemas de discriminación o sesgos entre clases sociales protegidas que se pueden ver perjudicadas por la ausencia de juicio humano en la concesión de crédito, y en la explicabilidad de sus resultados, donde se expone el problema sobre la discrepancia en las explicaciones que actualmente existe en la literatura académica, ilustrándolo con un ejercicio empírico. Por último, en la sección 4 se concluye con una serie de recomendaciones para economistas, expertos en *ML*, reguladores y supervisores financieros.

2. OPORTUNIDADES

En esta sección, vamos a analizar las oportunidades que ofrece el uso de *ML* en concesión de crédito. En primer lugar, analizamos las ganancias en capacidad de predicción con respecto a modelos tradicionales, y lo hacemos con una revisión de la literatura reciente, y con la realización de un ejercicio empírico. En segundo lugar, traducimos estas ganancias predictivas a impacto económico. Y finalmente, analizamos el posible efecto de *ML* en la inclusión financiera.

2.1. Mejor capacidad de predicción

2.1.1. Revisión de la literatura

Existen numerosos artículos académicos que analizan el uso de algoritmos de *ML* para la predicción de impagos en comparación con técnicas estadísticas tradicionales. Este apartado comienza repasando algunos de estos artículos a raíz de un resumen realizado en Alonso-Robisco y Carbo (2022a). En el **cuadro 1** se muestra un extracto de dichos artículos, junto con el tipo de préstamo subyacente (corporativos, consumo, o hipotecas), el tamaño de la muestra, el rendimiento estadístico de los modelos de *ML*, y el que obtienen con un *Logit* tradicional. En estos artículos el rendimiento estadístico se mide normalmente usando la métrica denominada *AUC-ROC*¹, que es un método de evaluación de sistemas de clasificación. La curva ROC se representa mediante la tasa de verdaderos positivos (*TPR*, por sus siglas en inglés) y la tasa de falsos positivos (*FPR*, por sus siglas en inglés), para todos los posibles umbrales de discriminación (Fawcett, 2006). En particular:

$$TPR = TP / (TP+FN)$$

$$FPR = FP / (FP+TN)$$

Donde *TP* (*true positives*) son los préstamos que, habiendo hecho impago, están correctamente estimados como tal; *FN* (*false negatives*) son los préstamos que, habiendo hecho impago, son incorrectamente estimados como no impagados; *FP* (*false positives*) son los préstamos que no impagaron, pero fueron estimados como impagos; y *TN* (*true negatives*) son los préstamos que no impagaron y correctamente se estimaron como no impagados. Así, para cada posible umbral, si un préstamo tiene una probabilidad de impago mayor que dicho umbral clasificaremos a ese préstamo como impagado. De este modo, cuanto menor es el umbral, mayor será la tasa *TPR* y menor la *FPR* (parte superior derecha de la curva ROC). Igualmente, a mayor umbral menor será la tasa *TPR* y mayor será la tasa *FPR* (parte inferior izquierda de la curva ROC).

Como alternativa al *AUC-ROC*, se muestra también en ocasiones la precisión, que es la tasa de verdaderos positivos entre el total de verdaderos y falsos positivos. Todas estas métricas, al representar tasas de acierto o fallo, tienen un rango igual a una probabilidad de ocurrencia, es decir, entre 0 y 100, y un mayor valor indica un mejor rendimiento estadístico.

Lo primero que destaca es que en todos los estudios revisados se encuentra una mejora en predicción estadística al usar modelos de *ML* (como *random forest*, *gradient boosting* o redes neuronales profundas) respecto a *Logit*. Estas ganancias pueden ser de hasta el 20 %. Observamos también que no necesariamente los modelos más complejos, como aquellos basados en redes neuronales, predicen mejor. De hecho, los resultados de estos artículos

¹ Por sus siglas en inglés, *Area Under the Curve of the Receiver Operator Characteristic*.

Cuadro 1.

Revisión de la literatura: precisión *ML* en predicción de impagos

<i>Autor, año, revista</i>	<i>Activo subyacente</i>	<i>Tamaño muestra</i>	<i>Predicción ML</i>	<i>Predicción Logit</i>
Jones, Johnstone y Wilson (2015) <i>Journal of Banking and Finance</i>	Préstamos corporativos	5.000 empresas en 20 años	<i>Random forest</i> 93 % AUC	83 % AUC
Petropoulos <i>et al.</i> (2019) <i>ECB, Working paper</i>	Préstamos corporativos	200.000 empresas	<i>Gradient boosting and neural net</i> 78 % AUC	66 % AUC
Sigrist y Hirsenschall (2019) <i>Journal of Banking and Finance</i>	Préstamos corporativos	850 préstamos a 141 pymes	<i>Grabit (Gradient boosting and Tobit)</i> 83% AUC	66 % AUC
Moscatelli <i>et al.</i> (2020) <i>Expert Systems with Applications</i>	Préstamos consumo	300.000 empresas	<i>Random forest</i> 75,9 % AUC	73,2 % AUC
Butaru <i>et al.</i> (2016) <i>Journal of Banking and Finance</i>	Préstamos consumo	1 millón de préstamos	<i>Random forest</i> 66,6 % Recall	59,2 % Recall
Kvamme <i>et al.</i> (2018) <i>Expert Systems with Applications</i>	Hipotecas	20.000 hipotecas	Convolutional neural net 91,5 % AUC	86,6 % AUC
Sirignano y Cont (2019) <i>Quantitative Finance</i>	Hipotecas	120 millones de hipotecas	<i>Grabit (Gradient boosting and Tobit)</i> 83 % AUC	66 % AUC
Albanesi y Vamossy (2019) <i>NBER, Working paper</i>	Préstamos consumo	1 millón de préstamos	<i>Neural net</i> 90 % Precision	86 % Precision

sugieren que los modelos basados en árboles de decisión como *Random forest* o *XGBoost* tienen mejor rendimiento predictivo.

2.1.2. Ejercicio empírico

Cabe resaltar que los datos usados por estos artículos son de variada naturaleza, difieren en tipo de préstamo subyacente y en el tamaño de muestra (desde unos pocos miles de préstamos a millones de ellos). Por lo tanto, con el objetivo de mejorar la comparabilidad de los resultados observados, en este apartado vamos a utilizar diferentes modelos de *ML* (árbol de decisión², *XGBoost*, red neuronal profunda) y un modelo *Logit* para predecir los impagos en una misma base de datos, de libre acceso, de crédito al consumo. En concreto, utilizamos la base de datos *Give me some credit*, accesible en la plataforma [Kaggle.com](https://www.kaggle.com). La base de datos forma parte de uno de los concursos de predicción más famosos de *credit scoring* en Kaggle,

² Forzamos al árbol de decisión a tener únicamente tres ramas, para que sea interpretable.

publicado en 2011. En las bases del concurso se menciona que se trata de datos de préstamos al consumo, aunque no se confirma si son datos reales. Los datos se componen de un total de 100.000 préstamos etiquetados con una variable objetivo de impago con una frecuencia del 6 %. Esta variable objetivo, *SeriousDlqin2yrs*, es una variable binaria que determina si el préstamo resultó fallido o no, en función de si el prestatario ha tardado más de 90 días en realizar el pago. El resto de variables cuantitativas, cuyas características se muestran en el **cuadro 2**, son las siguientes. *Revolving* se refiere al saldo total en tarjetas de crédito y líneas de crédito personales excepto patrimonio y sin deuda a plazos. Las variables *Age* y *Dependents* aluden a la edad del prestatario y al número de dependientes en la familia (cónyuge, hijos, etc.). Las variables *MonthlyIncome*, *DebtRatio* y *CreditLines* referidas a la renta mensual, al pago mensual de deuda, pensión alimenticia y costos de vida divididos por el ingreso bruto mensual, y al número de préstamos abiertos (a plazos, como préstamos para automóviles o hipotecas) y líneas de crédito (por ejemplo, tarjetas de crédito), respectivamente. Las variables *30-59Days* y *90Days* describen las veces que el prestatario se ha retrasado de 30 a 59 días, y de 60 a 89 días, respectivamente. Por último, *RealEstate* se refiere al número de préstamos hipotecarios, incluidas las líneas de crédito con garantía hipotecaria.

Cuadro 2.

Descripción de la *Give me some credit*

	<i>Default</i>	<i>Revolving</i>	<i>Age</i>	<i>30-59Days</i>	<i>DebtRatio</i>	<i>MonthlyIncome</i>	<i>CreditLines</i>	<i>90Days</i>	<i>RealEstate</i>	<i>Dependents</i>
mean	0.068	5.952	51.246	0.385	26.921	6635	8.752	0.216	1.054	0.852
std	0.253	266.619	14.410	3.558	394.013	13615	5.163	3.525	1.155	1.149
min	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
25 %	0.000	0.035	40.000	0.000	0.143	3400	5.000	0.000	0.000	0.000
50 %	0.000	0.178	51.000	0.000	0.296	5400	8.000	0.000	1.000	0.000
75 %	0.000	0.581	61.000	0.000	0.482	8226	11.000	0.000	2.000	2.000
max	1.000	50708.000	103.000	98.000	61106.500	3008750	58.000	98.000	54.000	20.000

Para realizar este ejercicio, se realiza una partición de 80 % para entrenar³, y 20 % para testear, utilizando los modelos anteriormente mencionados y evaluando su rendimiento en la muestra de test a través de diferentes métricas estadísticas. En concreto, se usa el anteriormente mencionado *AUC-ROC*, el *recall* y el *F1 score* (otra métrica con rango entre 0 y 100, que combina las métricas de *recall* y precisión). En el **cuadro 3** se muestran los resultados. Lo primero que llama la atención es que el *Logit*, el modelo estadístico tradicional, es el que peor rendimiento tiene en las tres medidas. Por ello, se propone utilizar un *Logit* al cuadrado, en el que seleccionamos las once variables explicativas e incluimos las variables al cuadrado para

³ De la muestra de entrenamiento, se selecciona un 20 % para validar. En esa muestra de validación, se eligen entre diferentes arquitecturas o hiperparámetros de los modelos de *ML* en función del *AUC* que consiguen. En el caso del árbol de decisión, el número de ramas se mantiene fijo en tres para que se pueda interpretar. En *XGBoost*, se elige la combinación de número de árboles y máximo de ramificaciones que obtiene un mayor *AUC* en la muestra de validación, y en el caso de las redes neuronales profundas, el número de capas internas y cantidad de nodos por capa.

ayudar al mismo a captar posibles no linealidades entre las variables. Su rendimiento mejora así considerablemente (medido en cualesquiera de las tres métricas), pero como veremos más adelante, la inclusión de variables al cuadrado empeorará la interpretabilidad del modelo, lo cual en principio era una de sus ventajas. En cualquier caso, los tres modelos de *ML* propuestos obtienen una mejor predicción estadística que los modelos *Logit*, siendo el modelo con mejor *AUC-ROC* y *F1 score* el *XGBoost*. Concluimos de esta manera que los resultados están en línea con la literatura académica antes mencionada, sumando evidencia de que los modelos más complejos de *ML* no necesariamente se comportan mejor en la clasificación de impagos.

Cuadro 3.

Give me some credit: métricas de rendimiento

	<i>Logit</i>	<i>Logit cuadrado</i>	<i>Árbol decisión</i>	<i>XGBoost</i>	<i>Red neuronal profunda</i>
<i>AUC-ROC</i>	0,64	0,78	0,81	0,84	0,82
<i>TPR / Recall</i>	0,61	0,61	0,71	0,74	0,75
<i>F1</i>	0,17	0,31	0,31	0,32	0,20

2.2. Impacto económico

Llegado este punto nos preguntamos, ¿cómo traducir esta mejora estadística en impacto económico? Existe un reducido número de estudios que tratan de monetizar el impacto de usar modelos de *ML* utilizados para tomar decisiones crediticias. Una de las propuestas pioneras se recoge en Khandani, Kim y Lo (2010) quienes calculan ahorros en costes de entre el 6 % y el 25 % medidos a través de las pérdidas totales por impagos usando datos de tarjetas de crédito, o Albanesi y Vamossy (2019) quienes usan redes neuronales en un modelo de evaluación crediticia obteniendo mejor rendimiento estadístico, y ahorros de hasta el 9 % medido a través de una métrica llamada “Valor Añadido”, siguiendo la siguiente ecuación, que usan para calcular el resultado neto derivado de los aciertos y errores del modelo utilizado para tomar las decisiones de concesión de créditos:

$$VA = TN \cdot B_d - FN \cdot B_r \cdot P_m \quad [1]$$

B_r : saldo pagadores; P_m : margen beneficios; B_d : saldo impagado; TN : verdaderos negativos; FN : falsos negativos.

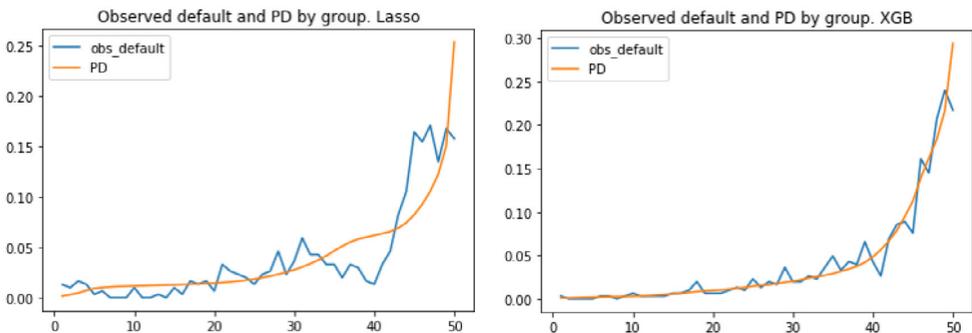
No obstante, es importante destacar que estas métricas de ahorro son retrospectivas, ya que sobre una cartera ya concedida se calcula el impacto en términos de ahorro entre un escenario donde se utiliza un modelo de *ML*, y un escenario en el que no se usa *ML*. Por lo tanto, no se trata de un importe económico que una entidad financiera pudiera materializar para valorar si implementar esta tecnología o no. Otra posible forma de calcular el impacto de predecir mejor los impagos es el posible ahorro en capital regulatorio. Un reciente estudio (Fraisie y Laporte, 2022) usa *ML* para predecir la probabilidad de impago de una cartera de bonos corporativos de una entidad financiera francesa y analiza los ahorros en capital regu-

latorio que dicha entidad podría obtener si usara *ML* bajo un enfoque de modelos internos (*Internal Rating Based* o *IRB*), los cuales alcanzarían hasta un 25 %. De manera similar, en nuestro estudio (Alonso-Robisco & Carbó, 2022b) se utiliza una base de datos de crédito al consumo de un banco español para estimar igualmente el ahorro de capital regulatorio, obteniendo hasta un 17 % en comparación con un cálculo del riesgo de esa exposición crediticia usando *Logit*.

Para ilustrar el porqué de estos ahorros, vamos a fijarnos en la **figura 1** de nuestro artículo (Alonso-Robisco & Carbo, 2022b). En esta figura se dividen las predicciones obtenidas con regresión logística penalizada vía *Lasso*⁴ (a la izquierda) y con *XGBoost* (a la derecha). Las predicciones se dividen en 50 grupos de igual número de préstamos, de forma ascendente en función de la probabilidad estimada de impago. Es decir, en el primer grupo están las predicciones con menor probabilidad de impago, y en el último grupo están las predicciones con mayor probabilidad de impago. La línea naranja indica la media de probabilidad estimada de cada grupo, y la línea azul la media de impagos observados en cada grupo. Cuanto más cercanas estén estas líneas, mejor será la predicción. Se puede observar a simple vista que las predicciones de *Lasso* infraestiman y sobreestiman la frecuencia observada de impagos. También, que la probabilidad de impago presenta una distribución donde en muchos grupos apenas cambia, no se diferencia bien entre préstamos. De este modo, teniendo en cuenta que el capital regulatorio es una función cóncava y creciente de la probabilidad de impago estimada, con el modelo tipo *Lasso* el capital regulatorio es mayor porque (i) tiende a sobreestimar para probabilidades de impago bajas y, (ii) no se pueden organizar los préstamos en grupos tan pequeños como se podría hacer con *XGBoost*, y dada la concavidad de la fórmula de capital regulatorio, cuantos más grupos se crean (mayor granularidad), más bajo será el capital regulatorio.

Figura 1.

***Logit*: variables más importantes según coeficiente**



⁴ Un modelo paramétrico lineal que, a diferencia de *Logit*, incluye mecanismos para eliminar variables con poco poder predictivo.

2.3. Mayor inclusión financiera

La automatización de las decisiones de crédito ofrece la posibilidad de democratizar el acceso a los servicios financieros. Por inclusión financiera la literatura económica distingue habitualmente tres aspectos: el acceso, la disponibilidad y el uso de servicios financieros (Sarma, 2008). Además, la exclusión financiera suele tener carácter involuntario y estar motivada por la carencia de ahorros, el coste de los servicios, la distancia o la ausencia de documentación, o la falta de educación financiera, entre otros. No obstante, también existen causas culturales y religiosas, o motivos como la desconfianza en el sistema financiero (Demirguc-Kunt *et al.*, 2018).

Una de las vías más importantes por las que la tecnología financiera permite influir en la inclusión financiera es principalmente a través de la recopilación granular de datos. Por ejemplo, el uso de la información con origen en la huella digital abriría posibilidades de financiación a individuos residentes en zonas no bancarizadas (Berg *et al.*, 2020), pero con recurso a otros proveedores financieros como plataformas de préstamos *online* (*crowdfunding*), donde el uso de *ML* es cada vez más extendido (véase la base de datos de crédito para competiciones entre científicos de datos de [Lending Club](#), en EE. UU.), o neobancos como el brasileño [Nubank](#). En este sentido, Philippon (2019) apunta a que el *big data* tiene el potencial de reducir los prejuicios negativos en la concesión de crédito, pero, a su vez, podría perjudicar la protección de determinadas minorías sociales. Asimismo, (Barruetabeña, 2020) concluye que la nueva generación de servicios financieros accesibles a través de los móviles e internet está contribuyendo al progreso en el sector financiero.

Dicha transformación se está dando, además, tanto por actores tradicionales como por nuevos agentes que están irrumpiendo en el mercado, ya sean grandes empresas tecnológicas (*bigtech*) o pequeñas compañías especializadas (*fintech*). La evidencia empírica muestra que una mayor competencia en la provisión de servicios financieros está reduciendo los costes de información y transformación asociados a la actividad crediticia (Philippon, 2019). Por ejemplo, un reciente trabajo (Fuster *et al.*, 2022) estudia la diferencia en la concesión de crédito hipotecario en EE. UU. entre *fintech* y bancos tradicionales, encontrando que los primeros son capaces de procesar la información hasta un 20 % más rápido sin aumentar la exposición a riesgo de impago. En esta línea, otros investigadores (Buchak *et al.*, 2018) encuentran que las empresas *fintechs* suelen atender a clientes con mayor nivel de renta, cobrando un diferencial de tipo de interés de entre 14-16 puntos básicos, concluyendo que los consumidores están dispuestos a pagar por decisiones rápidas y mejor experiencia de usuario. Así, esta parte de la literatura académica apunta a que las empresas *fintech* han mejorado la eficiencia en la provisión de crédito hipotecario, mostrándose como una vía prometedora para reducir la desigualdad en el acceso a financiación.

Es importante resaltar que el origen de esta mejora en la inclusión financiera no vendría únicamente a partir de la captura y uso de nuevos datos, sino también por el recurso a nuevas técnicas y modelos de *ML* que permiten captar nueva información de los mismos datos. Así queda de relieve en diversos estudios como Huang *et al.* (2020), donde se concluye que usar *big data* junto con modelos de *ML* ofrece ventajas significativas en la predicción de impagos de pequeñas y medianas empresas (pymes) en China, tanto por el uso de nuevos

datos alternativos (ventaja de información), como por la mayor flexibilidad de los nuevos métodos de predicción (ventaja de modelo). De manera similar, otros autores (Gambacorta *et al.*, 2019) sugieren que los algoritmos de *ML* pueden capturar mejor las relaciones no lineales entre variables en tiempos de estrés. Esto es especialmente relevante para determinadas clases sociales como los más jóvenes, quienes suelen carecer de historial crediticio, lo cual les imposibilita acceder a oportunidades de inversión (por ejemplo, en formación) a través de intermediarios financieros tradicionales. Así se pone de relieve en Agarwal *et al.* (2020) que describe como el uso de algoritmos de *ML* y los datos alternativos (en particular, el historial de navegación en el móvil), está facilitando en EE. UU. la predicción de impagos y el consiguiente acceso a financiación de la generación *millennial*. En esta misma línea, Qi y Xiao (2018) describen cómo la tecnología de *ML* aplicada para la concesión de microcréditos en China (de nuevo, donde los datos financieros son escasos o nulos), está mejorando la calidad de vida de las personas. En definitiva, existe evidencia que apunta hacia el potencial del *ML* para contribuir a un incremento responsable de inclusión financiera, no obstante, existiendo riesgos asociados a la adopción de esta tecnología (Bazarbash, 2019).

3. RIESGOS

Existe una extensa literatura que alerta de nuevos riesgos a la hora de aplicar *ML* en riesgo de crédito (BAFIN, 2022; Dupont, Fliche y Yang, 2020), desde la estabilidad de las predicciones, pasando por la transparencia de los algoritmos, o la privacidad de los datos. Para una correcta clasificación de estos factores de riesgo, y comprender cuáles son nuevos o genuinamente debidos al uso de esta tecnología financiera, podemos acudir a nuestro trabajo previo (Alonso-Robisco & Carbo, 2022a), donde se revisan y clasifican los factores asociados al uso de *ML* en tres categorías: estadística, tecnología y conducta de mercado, tal y como se muestra en el **cuadro 4**. Estos factores de riesgo están asociados a los requisitos que se exigen a los modelos cuantitativos usados en los esquemas de validación de modelos internos (*IRB*). Por ejemplo, en la validación de modelos de *IRB*, se exige que los modelos cuantitativos usados no sobreajusten, y sean interpretables, lo que se puede traducir en factores de riesgo a la hora de aplicar modelos de *ML*. De esta forma, encontramos hasta 13 potenciales factores de riesgo derivados del uso de *ML*.

Cuadro 4.

Factores de riesgo de modelo

<i>Estadística</i>	<i>Tecnología</i>	<i>Conducta de mercado</i>
Estabilidad	Transparencia	Privacidad de datos
Hiperparámetros	Huella de carbono	Auditabilidad
Sobreajuste	Dependencia de proveedores	Interpretabilidad
Calibración dinámica	Cyberataques	Sesgos
Preprocesamiento de datos		

Fuente: Alonso-Robisco y Carbó (2022a).

En concreto, dos de estos factores destacan por encima del resto (Institute of International Finance, 2018 y 2019), como son la interpretabilidad de los resultados y la discriminación financiera (sesgos), de los cuales hablaremos en las siguientes secciones.

3.1. Discriminación financiera (sesgos)

Recientes estudios (Fuster *et al.*, 2022) apuntan a que las últimas innovaciones en tecnología estadística (asociadas a *ML*) han provocado un aumento en el riesgo de impactos redistributivos en clases sociales protegidas como religión, género o raza. La pregunta sobre si las decisiones automatizadas de concesión de crédito promueven o mitigan la discriminación es especialmente relevante en el mercado de crédito al consumo, dada su repercusión sobre el bienestar de las familias. Estos impactos pueden venir por la mayor flexibilidad para descubrir relaciones estructurales o por triangulación de otras características previamente excluidas. Por ejemplo, a través del código postal se podría capturar la pertenencia a una determinada etnia en determinadas ciudades. De este modo, a pesar de eliminar variables sensibles de nuestra base de datos, de forma no intencionada podríamos incumplir políticas sociales de igualdad.

En este sentido, en Fuster *et al.* (2022), los autores se preguntan si son más laxas las condiciones de los préstamos que conceden las empresas *fintech* o tienen mejores sistemas de evaluación crediticia usando *ML*, encontrando que los prestamistas negros e hispanos están desproporcionadamente más desfavorecidos por la introducción de *ML*. En esta misma línea otros autores (Bartlett *et al.*, 2022) encuentran que aunque las *fintech* pueden reducir la discriminación, no la eliminan, y observan que los prestamistas negros e hispanos pagan un diferencial positivo de interés en préstamos hipotecarios, cuyo importe ascendería según sus estimaciones a 450 millones de dólares anuales que tendrían que sobrepagar; y por último, en otro estudio (Dobbie *et al.*, 2021) se encuentra que modelos de *ML* guiados por objetivos de largo plazo pueden aumentar el beneficio de las entidades financieras y reducir los sesgos, pero guiados por objetivos cortoplacistas penalizan a minorías como ancianos o inmigrantes.

Como conclusión de estos estudios podríamos destacar que la mejor capacidad predictiva de los algoritmos de *ML* proviene sensiblemente por un mejor uso de la información disponible. Sin embargo, una razón importante para evaluar su impacto a la hora de usarlo en la provisión de crédito es que el reparto entre ganadores y perdedores por el uso de esta tecnología puede estar desigualmente distribuido en la sociedad, especialmente a la hora de distinguir entre raza, edad o género de los consumidores o clientes. Para mitigar este riesgo existen nuevas herramientas, como las “explicaciones contrafactuales” (Wachter, Mittelstadt y Russel, 2017) que nos ayudan a averiguar qué factores o variables deberían cambiar para modificar una decisión de crédito tomada por un algoritmo.

3.2. Interpretabilidad de los resultados

3.2.1. Necesidad de interpretabilidad de las decisiones de crédito

¿Por qué queremos explicaciones de las decisiones que nos afectan? Los individuos tienden a buscar explicaciones ante eventos que no entienden, ya que una buena explicación puede facilitar el aprendizaje y crear un sentimiento de confianza (Miller, 2019). En el entorno de decisiones de crédito, la necesidad de las explicaciones cobra una especial importancia,

dado que son decisiones que pueden tener un impacto adverso en la vida de los usuarios. De hecho, como mencionamos anteriormente, la Directiva de Inteligencia Artificial (*AI Act*) incluye como actividades de alto riesgo en la aplicación de IA aquellas relacionadas con el riesgo de crédito, en concreto mencionando: “sistemas de IA [...] en la evaluación de la calidad crediticia o establecimiento de prioridad en el acceso a dichos servicios”. De modo similar, en EE. UU. existen regulaciones destinadas a eludir la discriminación en crédito, como son el *Equal Credit Opportunity Act (ECOA)* y *Fair Housing Act (FHA)*. Ambas normativas están centradas en evitar el *disparate treatment* y el *disparate impact*, dos conceptos de equidad crediticia. El primero se enfoca en si los prestamistas han tratado a los solicitantes de crédito de manera diferente según variables protegidas, como la raza o el género. El segundo aborda el uso por parte de los prestamistas de prácticas que puedan tener un efecto negativo desproporcionado en ciertos segmentos de la población. Para comprobar que no se incumplen estos dos conceptos, se exigen pruebas estadísticas y análisis de datos que pueden ser más difíciles de implementar para modelos complejos de *ML* que para modelos estadísticos sencillos. Además, se requiere a los proveedores financieros responder ante una solicitud de los clientes por decisión desfavorable (conocida como *adverse action notice*). No obstante, no existe todavía una obligación legal de “abrir las cajas negras”, puesto que no se reconoce el derecho de los usuarios a acceder al código de programación de los algoritmos (Wachter, Mittelstadt y Russel, 2017). Pero sí que existe un derecho a incluir el juicio humano en las decisiones de concesión de crédito, tal y como se establece en el artículo 22 del Reglamento General de Protección de Datos (*GDPR*, por sus siglas en inglés): “Todo interesado tendrá derecho a no ser objeto de una decisión basada únicamente en el tratamiento automatizado, incluida la elaboración de perfiles, que produzca efectos jurídicos en él o le afecte significativamente de modo similar.

Por lo tanto, queda patente que la normativa vigente exige cierto nivel de interpretabilidad en los modelos cuantitativos en riesgo de crédito. Esto se traduce en un riesgo que debe ser gestionado, porque mientras que los modelos econométricos tradicionales son inherentemente explicables, interpretar el resultado de los modelos de *ML* es más complicado. Es por ello que en los últimos años está floreciendo la disciplina de *Explainable AI (xAI)*, que se centra en interpretar los modelos de *ML*. En este campo, cuando hablamos de interpretar un modelo de *ML*, nos referimos a indicar qué variables son las más importantes en la salida de un modelo de *ML* para un individuo en particular (interpretabilidad global) y qué variables son las más relevantes para un conjunto de individuos (interpretabilidad global).

3.2.2. Técnicas de interpretabilidad de *ML*

Explainable AI engloba un conjunto amplio de herramientas (Hoffman *et al.*, 2018). En este artículo destacamos las conocidas como técnicas de interpretabilidad *post hoc*, las cuales se pueden aplicar a cualquier modelo de *ML* una vez entrenado, por ello también se les conoce como agnósticas. Algunas de las más populares son *SHAP – Shapley Additive exPlanations* (Lundberg, 2017), *LIME* (Ribeiro, Singh y Guestrin, 2016)⁵ y *permutation Feature*

⁵ Recientemente se ha propuesto una modificación más ambiciosa denominada Anchors (Ribeiro, Singh y Guestrin, 2018).

Importance o *FI* (Breiman, 2001). En general, todas ellas se basan en permutar de diferentes maneras las variables de entrada de los modelos para averiguar cómo cambia el resultado o predicción. En las siguientes secciones explicamos en más detalle cómo funcionan cada una de ellas.

Actualmente el uso de estas técnicas de interpretabilidad comienza a extenderse en la investigación académica de concesión de crédito (Tyagi, 2022), y en la propia industria financiera (Blattner *et al.*, 2021). Hoy entendemos además que diferentes usuarios de las decisiones de crédito pueden requerir diferentes tipos de explicaciones (Davis *et al.*, 2022). En concreto, las entidades financieras se beneficiarían de tener capacidad de explicación global (*SHAP*, *FI*) y local (*SHAP*, *LIME*) de los resultados, mientras que los clientes obtendrán información más valiosa a partir de ejemplos contrafactuales (Wachter, Mittelstadt y Russel, 2017) que les ayudarán a comprender qué cambios en determinadas variables podrían significar un cambio en la concesión o denegación del crédito. Por otro lado, los reguladores se podrían enfocarse en estresar el resultado de estas técnicas de interpretabilidad, tratando de asegurar su robustez. Por último, los ingenieros de datos deberán tratar de valorar la incertidumbre alrededor de sus estimaciones (*conformal ML*) y la posibilidad de explicar sus resultados con modelos más fácilmente comprensibles por otros usuarios (*surrogate models*).

Cabe recordar que, en última instancia, el uso de *ML* en finanzas suscita cuestiones éticas que deben ser examinadas con cautela, tales como integridad y justicia. Si bien tanto humanos como máquinas pueden errar en sus decisiones de concesión de créditos, lo importante es asegurar que se está usando el mejor juicio posible desde un punto de vista ético (Rizinski *et al.*, 2022), para lo cual no debemos nunca olvidar la necesidad de colaboración entre humanos y máquinas para lograr un proceso de decisión justo y eficiente.

Permutation Feature Importance

Permutation Feature Importance (también referida en este artículo como *feature importance*, o *FI*) es una técnica de evaluación *post hoc* que mide la importancia de una variable en la predicción del modelo en función del aumento del error en la predicción cuando cambiamos el valor de dicha variable. Se introdujo inicialmente para el modelo *random forest* (Breiman, 2001) aunque ya existen versiones agnósticas del mismo (Fisher *et al.*, 2019). Siguiendo con el ejemplo de datos de *Give me some credit*, imaginemos que hemos entrenado un modelo *XGBoost* para predecir impagos, y que estamos interesados en la importancia de la variable *Revolving*. En primer lugar, medimos el error en predicción obtenido con el modelo *XGBoost*. Hay diferentes medidas de error, pero dado que estamos en un problema de clasificación donde la variable a predecir es binaria, proponemos usar como métrica $(1 - \text{AUC-ROC})$, de forma que cuanto más alto es el *AUC-ROC*, más bajo es el error. A continuación, cambiamos el valor de *Revolving* de forma aleatoria, y estimamos de nuevo el error en la predicción. Repetimos el proceso n veces, para asegurarnos que los resultados no dependen de un cambio de valor en concreto. Después de n iteraciones, comparamos el error medio de esas repeticiones con el error del modelo original. Si la variable *Revolving* es importante, entonces el error medio obtenido debería ser mucho mayor que con el modelo original. Si la variable no es importante, entonces ambos errores deberían ser parecidos.

El método es simple, pero tiene un gran coste computacional. Implica repetir el proceso n veces para cada variable, por lo que cuanto mayor sea el número de variables, más tiempo llevará calcular sus importancias. Además, tiene dos inconvenientes adicionales. En primer lugar, se asume la independencia de variables entre ellas, algo que puede resultar poco realista en las decisiones de crédito. Por ejemplo, al cambiar de forma aleatoria el valor de las variables *Revolving*, el valor del resto de variables no cambia, lo que podría generar situaciones poco realistas. Por ejemplo, si suponemos que los préstamos *Revolving* se asocian a vencimientos cortos, nosotros no estaríamos restringiendo esta interacción entre ambas variables, permitiendo que existieran observaciones en nuestra simulación con vencimiento alto y estructura *Revolving*, en contra de lo que observamos en la realidad. Además, esta técnica no puede indicarnos la dirección del efecto de una determinada variable. Podemos saber si *Revolving* es importante, pero no si los aumentos o disminuciones en el valor de la variable están relacionados con aumentos o disminuciones en la probabilidad de impago.

SHAP

SHAP es una técnica que se basa en medir la contribución de una variable a la predicción de la probabilidad de impago, para un prestatario en particular, en comparación con la predicción promedio. Estas contribuciones se denominan “valores de Shapley” y nos darían información sobre la interpretabilidad local de nuestro modelo. Una vez que tenemos los valores de Shapley para cada variable y para cada prestatario, estos se pueden sumar para obtener la importancia global de la variable (*SHAP*). El proceso por el cual se calculan los valores de Shapley puede explicarse desde la perspectiva de la teoría de juegos. El juego sería reproducir el resultado del modelo (en nuestro caso, la probabilidad de impago). Los jugadores serían todas las posibles coaliciones de variables explicativas. Finalmente, la recompensa sería la contribución de cada coalición al resultado final del modelo. Veamos cómo funciona con un ejemplo. Supongamos que disponemos de una base de datos parecida a la de *Give me some credit*, pero donde únicamente tenemos tres variables explicativas: *Revolving*, “Edad” e “Ingresos”, además de la variable binaria a predecir, “Impago”. Imaginemos que estamos interesados en calcular la importancia de la variable *Revolving* en la probabilidad de impago de un individuo dado. Primero consideremos las cuatro posibles coaliciones de variables sin *Revolving*: Conjunto vacío, Edad, Ingresos, Edad e Ingresos.

Para las cuatro coaliciones, calculamos la probabilidad de impago del prestatario i con y sin la variable *Revolving*. El valor de Shapley de *Revolving* en relación con la probabilidad de impago para el prestatario i es el promedio ponderado de esas contribuciones marginales. Para obtener la importancia global de *Revolving* para la predicción de impago en toda la muestra, repetimos el proceso para todos los prestatarios de la base de datos, y calculamos el promedio de los valores de Shapley. Las variables con valores Shapley absolutos grandes se consideran variables locales importantes (y, en consecuencia, igualmente con valores agregados *SHAP*, para una explicación global). La técnica tiene dos problemas que también afectan a *permutation FI*. *SHAP* hace la suposición de que las variables no están correlacionadas, por lo que se generan coaliciones poco realistas. Y computacionalmente puede ser muy costoso también. Una ventaja con respecto a *permutation FI* es que aporta interpretabilidad local además

de la global, y además puede indicar la dirección del efecto de la variable en la probabilidad de impago. O sea, nos dice si la probabilidad aumenta o disminuye cuando el valor de la variable explicativa de interés es alto o bajo.

LIME

LIME o *Local Interpretable Model-Agnostic Explanations* es un modelo *post hoc* de interpretabilidad local y agnóstico. Como su nombre indica, *LIME* explica el resultado de modelos de *ML* aproximando el modelo subyacente por uno interpretable. Los modelos interpretables pueden ser modelos lineales con o sin regularización (por ejemplo, penalizando el tamaño de los coeficiente a través de técnicas como *Lasso* o *Ridge*), o árboles de decisión sencillos. Estos modelos interpretables se entrenan en pequeñas perturbaciones de los datos de entrada originales para predecir la predicción del modelo original subyacente. Imaginemos que hemos usado redes neuronales para predecir la probabilidad de impago de un préstamo concreto de nuestra base de datos. Si queremos usar *LIME* para explicar la predicción de ese préstamo, lo primero que deberíamos hacer es perturbar las variables explicativas de este préstamo agregando ruido a las variables continuas o eliminando algunas de ellas, y obtener la nueva predicción con nuestro modelo usando estos datos generados. Repetimos este proceso varias veces, otorgando un peso a estas nuevas muestras según su proximidad a los datos originales. Finalmente, usamos un modelo interpretable en estos nuevos datos, y explicamos las predicciones interpretando el modelo local. Una de sus ventajas es la relatividad facilidad para llevar a cabo el proceso, pero *LIME* también tiene sus puntos débiles. El mayor problema es la creación de las perturbaciones de datos, sobre todo para variables categóricas. No hay un consenso sobre cómo generar estos datos, y se pueden crear datos poco realistas. A su vez, las explicaciones pueden ser poco estables al depender de la perturbación de los datos y del modelo interpretable que se elige. Otro problema es que, a diferencia de los modelos anteriormente mencionados, no aporta interpretabilidad global.

3.2.3. El problema de la discrepancia en las interpretaciones

Como vemos, existe una amplia variedad de técnicas para explicar las razones por las que un modelo de *ML* ha tomado una decisión, lo cual a su vez puede crear un problema si existe discrepancia entre ellas, Krishna *et al.* (2022). Es decir, según la técnica utilizada, la conclusión sobre qué variables han sido más relevantes para un modelo puede variar. En Krishna *et al.* (2022) se establecen una serie de entrevistas con ingenieros de datos para entender cuándo existe una discrepancia entre explicaciones. Siguiendo este artículo, hay tres dimensiones a partir de las cuales podemos medir esta discrepancia. En primer lugar, podemos medir la discrepancia entre explicaciones en función del distinto *ranking* de variables importantes que ofrecen las diferentes técnicas. En segundo lugar, la discrepancia se puede medir en función de la magnitud de importancia asignada por las explicaciones a las diferentes variables (las técnicas como *SHAP* y *permutation FI* no solo indican el orden de importancia, también indican su magnitud). Por último, se puede medir la discrepancia en función de las explicaciones en diferentes momentos del tiempo. La preocupante realidad es que actualmente no existe un

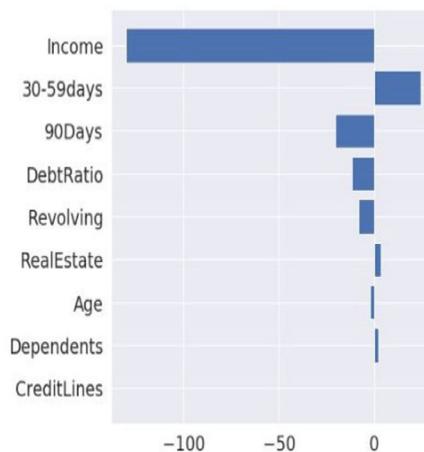
consenso sobre qué es una discrepancia ni sobre cómo resolverla. Para ilustrar el problema de la discrepancia de explicaciones proponemos de nuevo utilizar la base de datos *Give me some credit*. Además, añadiremos una dimensión a esta discrepancia, la cual descompondremos en dos componentes. Primero, la discrepancia entre modelos, bajo la cual un mismo individuo que se enfrenta a una decisión de concesión de crédito otorgada por un modelo basado en árboles o basado en redes neuronales, puede diferir. Para ilustrarlo, intentaremos explicar los resultados de los cinco modelos usados en el apartado 2.1 (*Logit*, *Logit* al cuadrado, árbol de decisión, *XGBoost*, y redes neuronales profundas), y veremos que en función del modelo de *ML* utilizado, encontraremos explicaciones muy diferentes. En segundo lugar, analizaremos la discrepancia dentro del mismo modelo, es decir, usando distintas técnicas de interpretabilidad sobre el mismo modelo de *ML* veremos cómo obtenemos resultados discrepantes también.

Discrepancia entre modelos

Partimos del modelo *Logit*, que es el más sencillo de interpretar, aunque su rendimiento en clasificación era el más bajo como vimos en el apartado 2.1. Dado que hemos estandarizado las magnitudes de las variables, podemos comparar directamente los coeficientes estimados de las variables para entender qué variables son las más importantes. Es por ello que *Logit* es un modelo inherentemente interpretable, sin necesidad de aplicar ninguna técnica de interpretabilidad *post hoc*. En la [figura 2](#) podemos ver las magnitudes de los coeficientes del *Logit* estimado, donde se ve claramente que la variable “Ingresos” es la más importante, con signo negativo, lo cual es de esperar, pues mayor nivel de “Ingresos” se asocia a menor probabilidad de impago.

Figura 2.

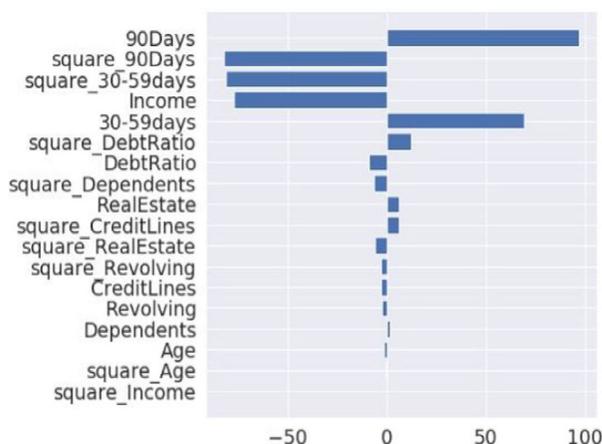
Logit: variables más importantes según coeficiente



En definitiva, el *Logit* es fácilmente interpretable pero su predicción es muy baja. Añadiendo variables al cuadrado podemos mejorar su poder predictivo como vimos anteriormente. Sin embargo, aunque todavía sería inherentemente interpretable, no es tan sencillo explicar qué variables son las más importantes puesto que hay que tener en cuenta los términos al cuadrado. En la [figura 3](#) mostramos la estimación de los coeficientes de *Logit* al cuadrado, y vemos que esta vez la variable *90Days* es la más importante, con signo positivo. Sin embargo, la segunda variable más importante es la variable *90Days* al cuadrado, con signo opuesto. Esto sugiere que cuantas más veces se retrase 90 días en el reembolso de sus obligaciones, más alta la probabilidad de impago del prestatario. Pero a partir de un número de días, mayor número es el retraso más disminuye la probabilidad de impago. Esto pone de manifiesto las limitaciones del *Logit*: a pesar de que incluir términos polinómicos para incluir no linealidades puede ayudar en la predicción, esto elimina la facilidad de interpretar el resultado del modelo.

Figura 3.

***Logit*²: variables más importantes según coeficiente**

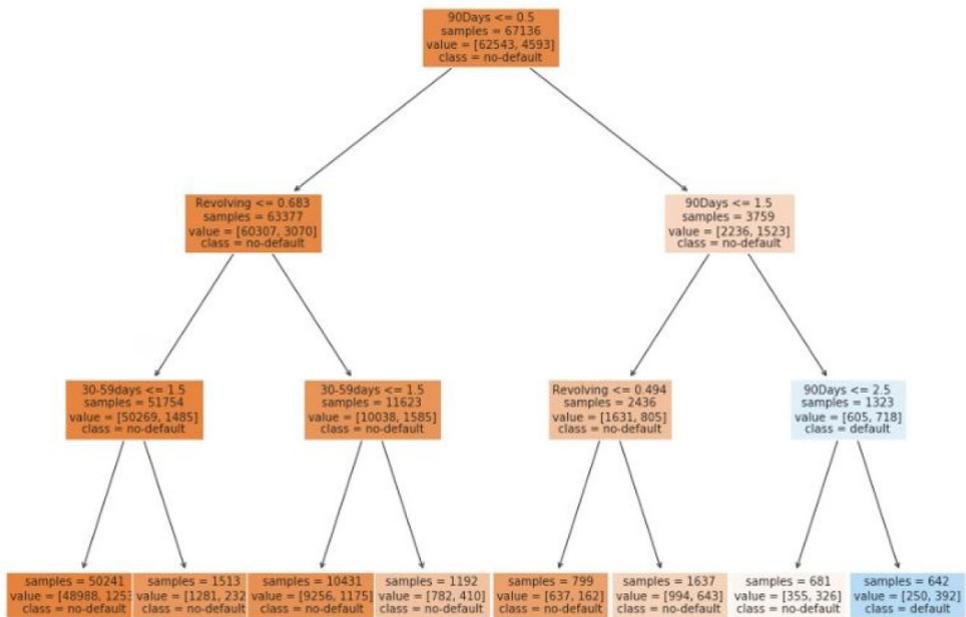


A continuación, pasamos a explicar las variables más importantes para el árbol de decisión. Al tratarse de un árbol sencillo, de solo tres ramas, podemos considerarlo un modelo inherentemente interpretable. En la [figura 4](#) mostramos el resultado del árbol que estimamos en el apartado 2.1. La forma para interpretar el árbol es la siguiente: en cada ramificación, se muestra la variable que el modelo ha usado para ramificar la muestra en dos, de forma que al final se creen grupos lo más homogéneos posibles (los impagos con los impagos, y los no impagos con los no impagos). Por ejemplo, siguiendo la [figura 4](#), la variable más importante es *90Days*, que es la que el modelo usa para ramificar la muestra al comienzo del árbol, dejando a la izquierda aquellas observaciones con *90Days* igual a cero, y a la derecha las observaciones con *90Days* mayor a cero. En las siguientes ramificaciones se sigue usando principalmente la variable *90Days*, manteniendo a la derecha en cada ramificación primero las que tienen *90Days* mayor a uno, y finalmente las que tienen *90Days* mayor a dos. Finalmente encontramos una ramificación donde hay más impagos (392) que no impago (250). El

hecho de que el árbol considere *90Days* como la variable más relevante encaja con la explicación de *Logit* al cuadrado. Sin embargo, como se aprecia en la [figura 4](#), la variable *Revolving* también se usa en muchas ramificaciones, y sin embargo no parece una de las más relevantes en *Logit* al cuadrado. Por lo tanto, aquí tenemos ya dos modelos inherentemente interpretables de *ML*, *Logit* al cuadrado y árbol, con un rendimiento de predicción parecido, pero con explicaciones diferentes.

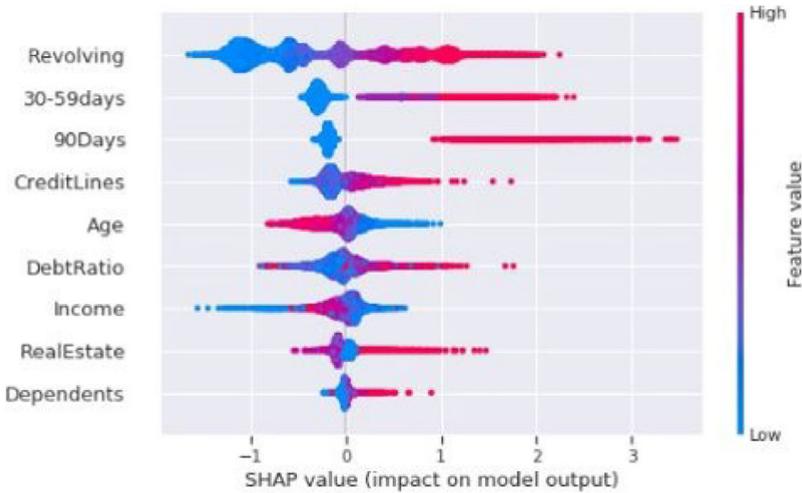
Figura 4.

Árbol de decisión: variables más importantes



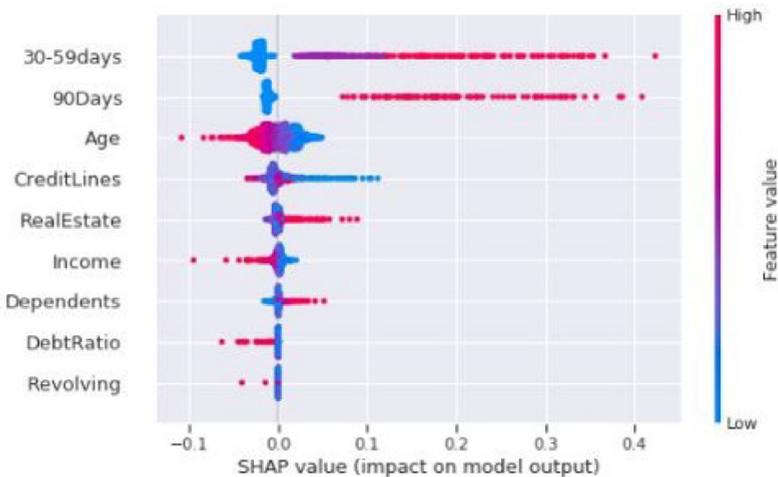
Por último, vamos a interpretar las variables más importantes para los modelos *XGBoost* y redes neuronales profundas. A diferencia de los tres modelos inherentemente interpretables vistos antes, para interpretar *XGBoost* y la red neuronal profunda es necesario usar una técnica de XAI. En este caso, vamos a usar *SHAP*, cuyo funcionamiento explicamos en la sección anterior. Mostramos en las [figuras 5](#) y [6](#) el resultado de *SHAP* para *XGBoost* y redes neuronales profundas, respectivamente. La imagen de *SHAP* corresponde con la salida de la aplicación de *Python tree.shap* para *XGBoost* y de *deep.shap* para redes neuronales profundas. Las variables aparecen ordenadas de mayor (arriba) a menor (abajo) importancia. En el eje horizontal se indica el impacto de la variable explicativa sobre nuestro objetivo a predecir. Los puntos azules corresponden con valores bajos de la variable, y los puntos rojos corresponden con valores altos. Por ejemplo, en 5, la variable más relevante es *Revolving*, y para valores bajos de *Revolving* (puntos azules), menor es la probabilidad de impago, mientras que para

Figura 5.

XGBoost: variables más importantes según SHAP

valores altos de *Revolving* (puntos rojos) mayor es la probabilidad de impago. En el caso de “Edad” (la quinta variable más importante), valores altos de la misma reducen la probabilidad de impago, y valores bajos de la variable aumentan la probabilidad de impago. Como queda patente viendo las figuras 5 y 6, la interpretación de *XGBoost* y de la red neuronal profunda

Figura 6.

Red neuronal profunda: variables más importantes según SHAP

a través de *SHAP* es completamente diferente. Por ejemplo, la variable más relevante para *XGBoost* es la menos importante para la red neuronal. Y la tercera variable más importante para la red neuronal es la sexta para *XGBoost*. Esto es así a pesar de haber usado la misma técnica de interpretabilidad *post hoc*.

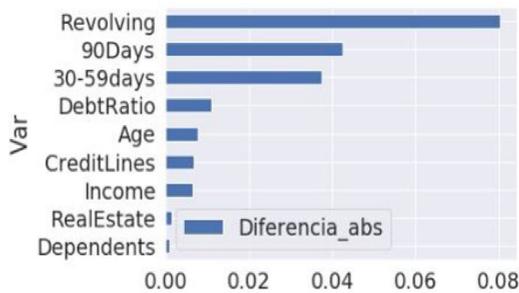
Como conclusión, esta evidencia muestra cómo las explicaciones de los modelos interpretables (*Logit* y árbol de decisión) no coinciden con las de los modelos no interpretables.

Discrepancias dentro del mismo modelo

Además de las fuertes discrepancias entre diferentes modelos de *ML*, en esta sección mostraremos que también existen discrepancias dentro de un mismo modelo de *ML*. Vamos a comparar la explicación de *XGBoost* con *SHAP 5*, con la explicación que nos brinda otra técnica de interpretabilidad global, *permutation FI* (ver figura 7). En este caso, ambas técnicas identifican como variable más relevante *Revolving*, pero existen diferencias en el resto del *ranking*, particularmente en cuanto a *DebtRatio*, “Edad”, “Ingresos”, etc. Mostrando que, por lo tanto, también puede haber discrepancias dentro del mismo modelo.

Figura 7.

XGBoost: variables más importantes según *permutation FI*



Hasta ahora hemos visto técnicas de interpretabilidad global. Pero, de modo similar, podemos observar discrepancias también si tratamos de explicar las predicciones préstamo a préstamo, o sea interpretabilidad local. Por ejemplo, para un mismo préstamo de la muestra, podemos explicar qué variables son las más importantes con valores de Shapley (ver figura 8) o con *LIME* (ver figura 9). Este prestamista tiene 65 años, una renta de 6.000 dólares, 19 “líneas de crédito”, valor de *Revolving* igual a 0,67, ha pagado entre 30 y 59 días tarde 3 veces, y ha pagado 90 días tarde 8 veces. Ambas técnicas coinciden con que *90Days* es la variable más relevante en la probabilidad de impago de este prestamista (cuanto mayor *90Days*, mayor probabilidad de impago), y que mayor “Edad” reduce la probabilidad de impago. Sin embargo, la importancia otorgada a *Revolving* difiere mucho en ambas explicaciones. Mientras que para *LIME* es la segunda más importante, para *SHAP* es prácticamente la menos

importante. De nuevo, un ejemplo de discrepancia entre *rankings*, esta vez buscando interpretabilidad local.

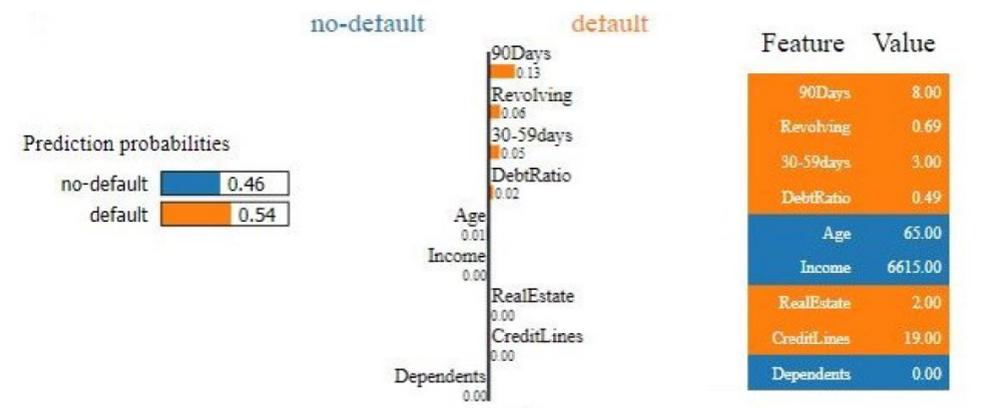
Figura 8.

XGBoost: variables más importantes según *SHAP*, a nivel local



Figura 9.

XGBoost: variables más importantes según *LIME*, a nivel local



A pesar de que pueden ser una herramienta fundamental para aplicar *ML* en decisiones de crédito, existen todavía muchas dudas sobre las técnicas de interpretabilidad *post hoc* ¿Cómo de preocupantes son las discrepancias entre técnicas? ¿Cómo de fiables y robustas son? ¿Son suficientes como explicación? (Miller, 2019). Motivados por estas preguntas, existe una literatura incipiente que trata de usar datos sintéticos para responder a algunas de estas preguntas. Generar datos sintéticos permite controlar y conocer la verdadera naturaleza de la relación entre variables, pudiendo comprobar hasta qué punto las explicaciones de las técnicas de interpretabilidad coinciden con las relaciones verdaderas entre los datos. Si bien, no existe un procedimiento estandarizado sobre cómo crear estos conjuntos de datos sintéticos. Por ejemplo hay estudios que (Barr *et al.*, 2020) usan cópulas gaussianas y demuestran que la correlación de variables redundantes puede afectar a las explicaciones dadas por *SHAP*. En esta línea, otros estudios (Aas, Jullum y Løland, 2021) modifican la implementación de *SHAP* para poder aproximar mejor las explicaciones cuando las variables explicativas tienen cierto nivel de dependencia. También usando datos sintéticos, estudios como Hall *et al.* (2021) y

Zhang *et al.* (2019) demuestran que existen varias fuentes de incertidumbre e inestabilidad para *LIME*. Por último mencionar que en nuestro trabajo (Alonso-Robisco & Carbo, 2022d) proponemos la generación de datos sintéticos para crear un entorno controlado donde realizar un *stress test* de estas técnicas. Nuestros datos generados representan escenarios similares a las condiciones normalmente observadas en entornos de crédito, y nuestros resultados sugieren que *SHAP* es mejor que *permutation FI* capturando características relevantes, aunque las explicaciones pueden variar significativamente según las características del conjunto de datos y el modelo *ML* utilizado, por lo tanto, se requiere cautela para generalizar unas conclusiones sobre la precisión de estas técnicas.

4. CONCLUSIONES

Los modelos de *ML* pueden revolucionar el campo de la concesión de crédito, creando sistemas automáticos de decisión que mejoren tanto la experiencia del usuario (por ejemplo, la velocidad de concesión del crédito), sin empeorar la exposición de riesgo de los proveedores de crédito (Gambacorta *et al.*, 2019). Estas mejoras se deben tanto a la capacidad de esta tecnología financiera para gestionar grandes cantidades de datos (*big data*), como a la mayor flexibilidad de estos modelos predictivos para captar relaciones no lineales entre las variables (Fuster *et al.*, 2022; Gimeno y Sevillano, 2022; Hoffman *et al.*, 2018). De hecho, como hemos visto, su mayor rendimiento estadístico se puede llegar a traducir en clasificaciones más granulares del activo ponderado por riesgo, derivando en un menor consumo potencial de capital regulatorio (Alonso-Robisco & Carbo, 2022d); Fraisse y Laporte, 2022) e inclusive, a gran escala, en mayor inclusión financiera (Berg *et al.*, 2020; Buchak, 2018; Barruetaña, 2020).

No obstante, el uso de *ML* trae consigo una serie de consecuencias no intencionadas, en la forma de nuevos factores de riesgo (Alonso-Robisco & Carbo, 2022a). Son de especial relevancia para los supervisores financieros la discriminación y la interpretabilidad de los resultados (BAFIN, 2022; Blattner, Nelson y Spiess, 2021; Dupont, Fliche y Yang, 2020). En cuanto a la discriminación, el uso de *ML* puede dificultar el cumplimiento de determinadas políticas de equidad en la concesión de crédito (Philippon, 2019). Esta preocupación se sostiene en numerosos estudios que demuestran que los sistemas de concesión de crédito basados en *ML* perjudican especialmente a minorías sociales o a la población de elevada edad (Bartlett *et al.*, 2022; Dobbie *et al.*, 2021). Por ello, nuevos actos legislativos dedicados a la regulación de los sistemas basados en inteligencia artificial, como por ejemplo, la Directiva Europea de Inteligencia Artificial (*AI Act*) clasifican el uso de esta tecnología para la concesión de crédito como un área de alto riesgo, debido al potencial impacto negativo en la solvencia de las empresas y el bienestar de las personas que se enfrentan a este tipo de decisiones automatizadas. En cuanto a la interpretabilidad, la reciente normativa sobre privacidad de los datos (*GDPR*, por sus siglas en inglés), establece la necesidad de transparencia e inclusión del juicio humano en decisiones donde se hace un perfilado del riesgo de los clientes. Esto puede ser un problema en la aplicación de *ML* en crédito debido a la dificultad para explicar las decisiones de estos modelos. Existen herramientas novedosas que podrían ayudar a mitigar estos

problemas de explicabilidad, conformando un campo conocido como *Explainable AI (xAI)*. Dentro de este campo, pueden ser de especial interés para el uso en sistemas de evaluación del riesgo crediticio las conocidas como técnicas de interpretabilidad *post hoc*, las cuales pueden ser utilizadas para explicar los resultados de cualquier modelo de *ML* previamente entrenado.

En este capítulo, para ilustrar tanto las oportunidades derivadas de la mayor capacidad predictiva de estos modelos, como los nuevos riesgos asociados a la explicabilidad de sus resultados, realizamos un ejercicio empírico con una base de datos de libre acceso denominada *Give Me Some Credit*. Estimamos cinco modelos de *ML* comúnmente utilizados para la predicción de impagos, como son *Logit*, árboles de decisión, *random forest*, *XGBoost* y redes neuronales profundas. Tras evidenciar su mejor rendimiento estadístico tratamos de interpretar sus resultados a través de tres técnicas: *SHAP*, *permutation FI* y *LIME*, poniendo de relieve la existencia de un problema por la discrepancia de explicaciones (Krishna *et al.*, 2022), tanto dentro de cada modelo, comparando distintas técnicas de interpretabilidad; como entre modelos, usando la misma técnica, pero aplicada a distintos modelos predictivos.

Sin duda, para lograr una implementación de esta tecnología a mayor escala en el sistema financiero será necesario lograr robustas herramientas que logren satisfacer las necesidades de explicación de todos los agentes que intervienen en un proceso de concesión de crédito: entidades financieras, consumidores, reguladores y científicos de datos (Davis *et al.*, 2022). La solución a los problemas derivados del uso de sistemas de *ML* posiblemente no radique en usar exclusivamente más *ML (xAI)*, por lo que debemos prestar especial atención al uso responsable de esta tecnología, siguiendo unos principios éticos (Rizinski *et al.*, 2022), sin olvidarnos de que esta tecnología no es sustitutiva de la actual econometría, sino complementaria (Alonso-Robisco & Carbo, 2022c); Kaji *et al.*, 2020). Por ello, concluimos con un llamamiento hacia la colaboración interdisciplinar, entre economistas e ingenieros, haciendo especial énfasis en la formación en técnicas de *ML* a los profesionales del sector financiero, gestores de riesgos, y economistas dedicados a la investigación académica (Athey e Imbens, 2019).

Referencias

- AAS, K., JULLUM, M. y LØLAND, A. (2021). Explaining individual predictions when features are dependent: More accurate approximations to Shapley values. *Artificial Intelligence*, 298, 103502.
- AGARWAL, S., ALOK, S., GHOSH, P. y GUPTA, S. (2020). Financial inclusion and alternate credit scoring for the millennials: Role of big data and machine learning in fintech. *Business School, National University of Singapore Working Paper*, SSRN, 3507827.
- ALBANESI, S. y VAMOSSY, D. F. (2019). Predicting consumer default: A deep learning approach (No. w26165). National Bureau of Economic Research.
- ALONSO-ROBISCO, A. y CARBO MARTINEZ, J. M. (2022a). Measuring the model risk-adjusted performance of machine learning algorithms in credit default prediction. *Financial Innovation*, 8(1), pp. 1-35.
- ALONSO-ROBISCO, A. y CARBO MARTINEZ, J. M. (2022b). Can machine learning models save capital for banks? Evidence from a Spanish credit portfolio. *International Review of Financial Analysis*, 84, 102372.

- ALONSO-ROBISCO, A. y CARBÓ, J. M. (2022c). Inteligencia Artificial y Finanzas: Una Alianza Estratégica (Artificial Intelligence and Finance: A Strategic Alliance). *Banco de España Occasional Paper*, 2222.
- ALONSO-ROBISCO, A. y CARBÓ, J. M. (2022d). "Accuracy of explanations of machine learning models for credit decisions," *Working Papers* 2222, Banco de España.
- ATHEY, S. e IMBENS, G. W. (2019). Machine learning methods that economists should know about. *Annual Review of Economics*, 11, pp 685-725.
- BAFIN (2022). Machine learning in risk models – characteristics and supervisory priorities. responses to the consultation paper. Rep. Germany: Federal Financial Supervisory Authority.
- BARTLETT, R., MORSE, A., STANTON, R. y WALLACE, N. (2022). Consumer-lending discrimination in the FinTech era. *Journal of Financial Economics*, 143(1), pp. 30-56.
- BARR, B., XU, K., SILVA, C., BERTINI, E., REILLY, R., BRUSS, C. B. y WITTENBACH, J. D. (2020). Towards ground truth explainability on tabular data. *arXiv preprint arXiv:2007.10532*.
- BARRUETABEÑA LORENTE, E. (2020). La influencia de las nuevas tecnologías en la inclusión financiera. *Boletín económico/Banco de España [Artículos]*, n. 1.
- BAZARBASH, M. (2019). Fintech in financial inclusion: machine learning applications in assessing credit risk. International Monetary Fund.
- BERG, T., BURG, V., GOMBOVIĆ, A. y PURI, M. (2020). On the rise of fintechns: Credit scoring using digital footprints. *The Review of Financial Studies*, 33(7), pp. 2845-2897.
- BLATTNER, L., NELSON, S. y SPIESS, J. (2021). Unpacking the black box: Regulating algorithmic decisions. *arXiv preprint arXiv:2110.03443*.
- BLATTNER, L., STARK, PR., SPIESS, J., McELFRESH, D., YAZDI, S. y KALASHNOV, G. (2021). Machine Learning Explainability & Fairness: Insights from Consumer Lending. *finreglab.org*.
- BREIMAN, L. (2001). Statistical modeling: The two cultures (with comments and a rejoinder by the author). *Statistical science*, 16(3), pp. 199-231.
- BREIMAN, L. (2001). Random forests. *Machine learning*, 1, pp. 5-32
- BUCHAK, G., MATVOS, G., PISKORSKI, T. y SERU, A. (2018). Fintech, regulatory arbitrage, and the rise of shadow banks. *Journal of Financial Economics* 130(3), pp. 453– 483.
- BUTARU, F., CHEN, Q., CLARK, B., DAS, S., LO, A. W. y SIDDIQUE, A. (2016). Risk and risk management in the credit card industry. *Journal of Banking & Finance*, 72, pp. 218-239.
- DAVIS, R., LO, A. W., MISHRA, S., NOURIAN, A., SINGH, M., WU, N. y ZHANG, R. (2022). *Explainable Machine Learning Models of Consumer Credit Risk*. Available at SSRN.
- DEMIRGUC-KUNT, A., KLAPPER, L., SINGER, D. y ANSAR, S. (2018). *The Global Findex Database 2017: Measuring financial inclusion and the fintech revolution*. World Bank Publications.
- DOBBIE, W., LIBERMAN, A., PARAVISINI, D. y PATHANIA, V. (2021). Measuring bias in consumer lending. *The Review of Economic Studies*, 88(6), pp. 2799-2832.
- DUPONT, L., FLICHE, O. y YANG, S. (2020). *Governance of Artificial Intelligence in Finance*. Banque De France.
- EBA. (2021). Discussion paper on machine learning for IRB models. EBA/DP/2021/04. November 2021.
- ESTÉVEZ ALMENZAR, M., FERNÁNDEZ LLORCA, D., GÓMEZ, E. y MARTINEZ PLUMED, F. (2022). Glossary of human-centric artificial intelligence (No. JRC129614). Joint Research Centre (Seville site).
- FAWCETT, T. (2006). An introduction to ROC analysis. *Pattern recognition letters*, 27(8), pp. 861-874.
- FERNÁNDEZ, A. (2019). Inteligencia artificial en los servicios financieros. *Boletín Económico* 2/2019. Artículos Analíticos. Banco de España.

- FISHER, A., RUDIN, C. y DOMINICI, F. (2019). All Models are Wrong, but Many are Useful: Learning a Variable's Importance by Studying an Entire Class of Prediction Models Simultaneously. *J. Mach. Learn. Res.*, 20, 177, pp-1-81.
- FRAISSE, H. y LAPORTE, M. (2022). Return on investment on artificial intelligence: The case of bank capital requirement. *Journal of Banking and Finance*, 138, 106401.
- FLORIDI, L., HOLWEG, M., TADDEO, M., AMAYA SILVA, J., MÖKANDER, J. y WEN, Y. (2022). capAI-A Procedure for Conducting Conformity Assessment of AI Systems in Line with the EU Artificial Intelligence Act. Available at SSRN 4064091.
- FUSTER, A., GOLDSMITH-PINKHAM, P., RAMADORAI, T. y WALTHER, A. (2022). Predictably unequal? The effects of machine learning on credit markets. *The Journal of Finance*, 77(1), pp. 5-47.
- GAMBACORTA, L., HUANG, Y., QIU, H. y WANG, J. (2019). *How do machine learning and non-traditional data affect credit scoring? New evidence from a Chinese fintech firm.*
- GIMENO, R. y SEVILLANO, J. M. M. (2022). Tradición e inteligencia artificial: oportunidades y retos del machine learning para los servicios financieros. Información Comercial Española, ICE: *Revista de economía*, (926), pp. 109-118.
- GOODELL, J. W., KUMAR, S., LIM, W. M. y PATTNAIK, D. (2021). Artificial intelligence and machine learning in finance: Identifying foundations, themes, and research clusters from bibliometric analysis. *Journal of Behavioral and Experimental Finance*, 32, 100577.
- HALL, P., COX, B., DICKERSON, S., KANNAN, R., ARJUN, KULKARNI, R. y SCHMIDT, N. (2021). A United States fair lending perspective on machine learning. *Frontiers in Artificial Intelligence*, 4.
- HOFFMAN, R. R., MUELLER, S. T., KLEIN, G. y LITMAN, J. (2018). Metrics for explainable AI: Challenges and prospects. *arXiv preprint arXiv:1812.04608*.
- HUANG, Y., ZHANG, L., LI, Z., QIU, H., SUN, T. y WANG, X. (2020). *Fintech credit risk assessment for SMEs: Evidence from China.*
- INSTITUTE OF INTERNATIONAL FINANCE. (2018). *Explainability in predictive modelling.*
- INSTITUTE OF INTERNATIONAL FINANCE. (2019). *Machine learning in credit risk.*
- INSTITUTE OF INTERNATIONAL FINANCE. (2019). *Bias and Ethical Implications in Machine Learning.*
- JONES, S., JOHNSTONE, D. y WILSON, R. (2015). An empirical evaluation of the performance of binary classifiers in the prediction of credit ratings changes. *Journal of Banking and Finance*, 56, pp. 72-85.
- JUNG, C., MUELLER, H., PEDEMONTE, S., PLANCES, S. y THEW, O. (2019). *Machine learning in UK financial services.* Bank of England and Financial Conduct Authority.
- KAJI, T., MANRESA, E. y POULIOT, G. (2020). An adversarial approach to structural estimation. *arXiv preprint arXiv:2007.06169*.
- KHANDANI, A. E., KIM, A. J. y LO, A. W. (2010). Consumer credit-risk models via machine-learning algorithms. *Journal of Banking and Finance*, 34(11), pp. 2767-2787.
- KÖNIGSTORFER, F. y THALMANN, S. (2020). Applications of Artificial Intelligence in commercial banks—A research agenda for behavioral finance. *Journal of behavioral and experimental finance*, 27, 100352.
- KRISHNA, S., HAN, T., GU, A., POMBRA, J., JABBARI, S., WU, S. y LAKKARAJU, H. (2022). The Disagreement Problem in Explainable Machine Learning: A Practitioner's Perspective. *arXiv preprint arXiv:2202.01602*.
- KVAMME, H., SELLEREITE, N., AAS, K. y SJURSEN, S. (2018). Predicting mortgage default using convolutional neural networks. *Expert Systems with Applications*, 102, pp. 207-217.
- LUNDBERG, S. y LEE, S. (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30.

- MILLER, T. (2019). Explanation in artificial intelligence: Insights from the social sciences. *Artificial intelligence*, 267, pp. 1-38.
- MOSCATELLI, M., PARLAPIANO, F., NARIZZANO, S. y VIGGIANO, G. (2020). Corporate default forecasting with machine learning. *Expert Systems with Applications*, 161, 113567.
- PETROPOULOS, A., SIAKOULIS, V., STAVROULAKIS, E. y KLAMARGIAS, A. (2019). A robust machine learning approach for credit risk analysis of large loan level datasets using deep learning and extreme gradient boosting. *IFC Bulletins chapters*, 49.
- PHILIPPON, T. (2019). On fintech and financial inclusion (No. w26330). National Bureau of Economic Research.
- PETRALIA, K., PHILIPPON, T., RICE, T. y VÉRON, N. (2019). Banking disrupted? financial intermediation in an era of transformational technology. Technical Report 22, Geneva Reports on the World Economy, ICMB and CEPR.
- QI, Y. y XIAO, J. (2018). Fintech: AI powers financial services to improve people's lives. *Communications of the ACM*, 61(11), pp. 65-69.
- RIBEIRO, M., SINGH, S. y GUESTRIN, C. (2016). Model-agnostic interpretability of machine learning. *arXiv preprint arXiv:1606.05386*.
- RIBEIRO, M. T., SINGH, S. y GUESTRIN, C. (2018, April). Anchors: High-precision model-agnostic explanations. In *Proceedings of the AAAI conference on artificial intelligence (Vol. 32, No. 1)*.
- RIZINSKI, M., PESHOV, H., MISHEV, K. y CHITKUSHEV, L. T., VODENSKA, I. y TRAJANOV, D. (2022). Ethically Responsible Machine Learning in Fintech. *IEEE Access*, 10, pp-97531-97554
- SARMA, M. (2008). Index of financial inclusion (No. 215). *Working paper*.
- SIGRIST, F. y HIRNSCHALL, C. (2019). Grabit: Gradient tree-boosted Tobit models for default prediction. *Journal of Banking and Finance*, 102, pp. 177-192.
- SIRIGNANO, J. y CONT, R. (2019). Universal features of price formation in financial markets: perspectives from deep learning. *Quantitative Finance*, 19(9), pp. 1449-1459.
- TYAGI, S. (2022). Analyzing Machine Learning Models for Credit Scoring with Explainable AI and Optimizing Investment Decisions. *arXiv preprint arXiv:2209.09362*.
- WACHTER, S., MITTELSTADT, B. y RUSSEL, C. (2017). Counterfactual explanations without opening the black box: Automated decisions and the GDPR. *Harv. JL & Tech.*, 31, pp. 841-.
- ZHANG, Y., SONG, K., SUN, Y., TAN, S. y UDELL, M. (2019). "Why Should You Trust My Explanation?" Understanding Uncertainty in LIME Explanations. *arXiv preprint arXiv:1904.12991*.

CAPÍTULO IV

¿Es posible batir a los mercados financieros usando herramientas de *big data* y de *machine learning*?

Francisco J. Nogales*

Una de las premisas de la teoría económica financiera es la hipótesis del mercado eficiente: los precios de los activos financieros incorporan toda la información pública disponible. El consenso actual es que los mercados financieros no son 100 % eficientes en todo momento, por lo que siempre existen pequeñas anomalías que pueden ser explotadas para generar rentabilidades por encima del mercado.

En este trabajo se revisarán las herramientas de *machine learning* propuestas en los últimos años, en el contexto del *big data* financiero, para explotar las mencionadas anomalías, y desarrollar estrategias automáticas de inversión para tratar de batir a los mercados.

Palabras clave: aprendizaje automático, estrategias de inversión, grandes volúmenes de datos, interacciones y no linealidades.

* El autor agradece el apoyo financiero del Gobierno de España a través del proyecto de investigación PID2020-116694GB-I00.

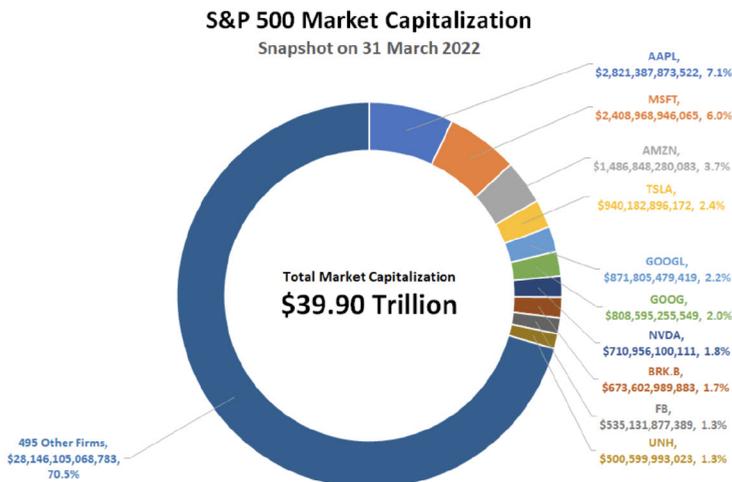
1. INTRODUCCIÓN Y MOTIVACIÓN

Empecemos definiendo en primer lugar qué se entiende por un mercado, y qué significa batir al mercado. La definición estándar de mercado viene dada por un índice financiero, que es una media ponderada por la capitalización bursátil de cada una de las compañías que componen el índice. El índice financiero más conocido en el mundo es el Standard & Poor's S&P 500.

A continuación, en la **figura 1**, se muestra la composición del S&P 500 a fecha 31 de marzo de 2022. Se puede observar cómo el índice está fuertemente concentrado en pocas empresas. En particular, diez empresas representan el 30 % del índice.

Figura 1.

Porcentaje de capitalización de las empresas componentes del S&P 500



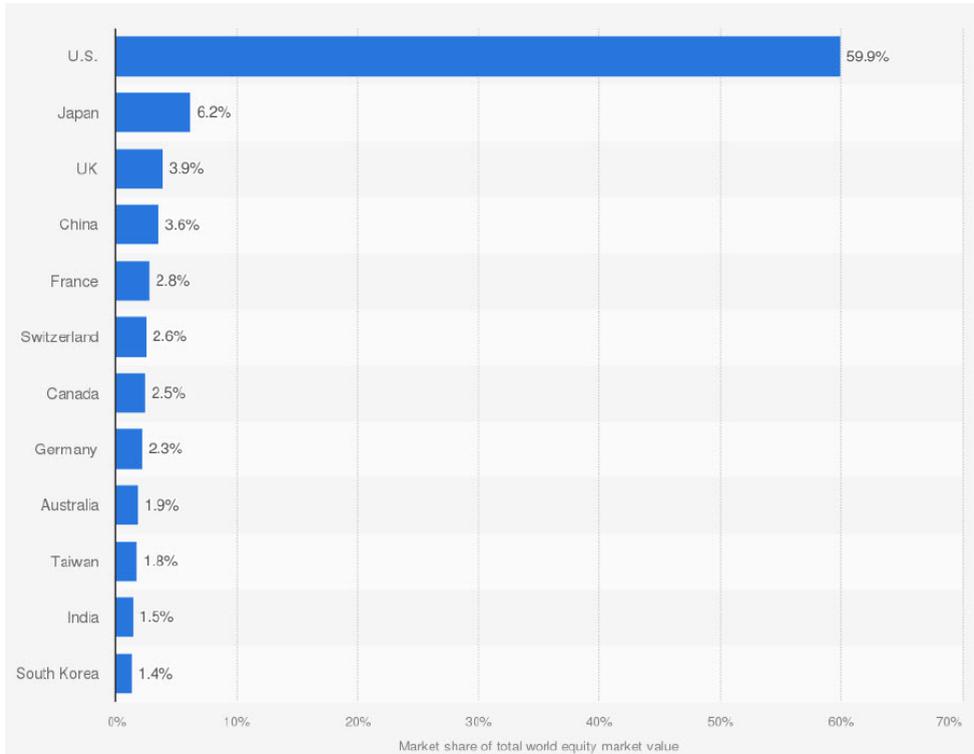
Fuente: Standard & Poor's, Slickcharts.

En la **figura 2** se presenta la composición de un índice internacional a fecha enero de 2022. También se observa cómo unos pocos países están sobreponderados en el índice, en particular EE. UU. representa el 60 % de la capitalización bursátil mundial.

En el mercado español, el índice más conocido es el Ibex 35, representando a las 35 compañías con mayor volumen negociado. De nuevo, solamente cuatro compañías representan más del 40 % de la capitalización total. En resumen, un mercado es un índice financiero habitualmente concentrado en unas pocas componentes.

Una vez fijado un índice de mercado concreto, podemos definir el término *batir al mercado* como la habilidad de conseguir mejores rentabilidades por unidad de riesgo, de forma consistente y prolongada, que el propio índice.

Figura 2.

Porcentaje de capitalización de los países con mayor capitalización bursátil en el mundo

Fuentes: Credit Suisse, FTSE.

Desde los años sesenta, una de las premisas populares de la teoría económica financiera es la hipótesis del mercado eficiente: en todo momento, los precios de los activos financieros incorporan toda la información pública disponible. Por tanto, si dicha hipótesis es cierta, no hay forma de batir al mercado: esto es, no sería posible desarrollar estrategias de inversión que obtengan rentabilidades, de forma consistente y prolongada, por encima de la media del mercado (representado por un índice, por ejemplo, el S&P 500).

Por otra parte, son bien conocidos inversores (Buffet, Lynch), compañías (AQR, Renaissance), y estilos de inversión (*momentum*, *value*) que han obtenido rentabilidades superiores al mercado a lo largo de los años. Además, existe evidencia de que ciertas estrategias y estilos de inversión (por ejemplo, *momentum* y *value investing*) que también son capaces de batir al mercado de forma consistente en el largo plazo.

Por estos motivos, actualmente existe consenso al pensar que los mercados financieros no son 100 % eficientes en todo momento, por lo que siempre pueden existir pequeñas

anomalías (desviaciones de la eficiencia) que pueden ser explotadas por los inversores para generar rentabilidades por encima del mercado.

Y es en este contexto donde las herramientas de *big data* y de *machine learning* resultan prometedoras para explotar anomalías, ya que actualmente existen grandes volúmenes de datos de activos financieros capaces de procesar y extraer información valiosa. Esta información es el punto de partida para que modelos recientes de ciencia de datos (estadística avanzada y herramientas de *machine learning*) puedan encontrar relaciones complejas entre dichos activos, y conseguir así predicciones suficientemente precisas que logren batir al mercado.

Pero la principal cuestión permanece: ¿hasta qué punto estas nuevas herramientas pueden conseguir mejores rentabilidades del mercado? Las anomalías que aparecen en los mercados son pequeñas, complejas, y dinámicas en el tiempo (pueden permanecer, pero también desaparecer), y por tanto la predictibilidad futura de las rentabilidades (en base a datos pasados) también será pequeña. En lenguaje estadístico, significa que la ratio señal-ruido en los datos financieros es muy próxima a cero.

En este artículo se hará un repaso a las herramientas de estadística avanzada y de *machine learning* que han ido apareciendo en los últimos años. Estas herramientas, en el actual contexto de *big data* financiero, tratan de explotar al máximo la baja predictibilidad existente, para desarrollar estrategias de inversión que intentan batir al mercado: el conocido valor del *big data* financiero. Con este repaso, se analizará si es posible batir al mercado, en qué condiciones, y hasta qué punto.

En particular, en la sección 2 se introducirán los modelos avanzados de estadística para reducir la variabilidad explicada en el valor esperado de las rentabilidades. En la sección 3 se presentarán los últimos avances en *machine learning* para explotar la escasa predictibilidad existente, y desarrollar así estrategias automáticas de inversión basadas en las predicciones de las herramientas de *machine learning*. En la sección 4 se mostrará una aplicación real donde se comparan todas las herramientas presentadas, y se mide la ganancia económica de las mismas a través de un *backtesting* exhaustivo en el mercado de acciones de EE. UU. La sección 5 trata de analizar las relaciones entre los predictores y las rentabilidades a predecir. Finalmente, la sección 6 presenta las principales conclusiones del trabajo.

2. METODOLOGÍA ESTADÍSTICA: MODELOS FACTORIALES

El modelo *CAPM* (*Capital Asset Pricing Model*) permite describir la relación entre el riesgo asociado al mercado y la rentabilidad asociada a cada activo (o compañía que cotiza en bolsa). Por tanto, es un modelo econométrico que establece una relación lineal entre la rentabilidad esperada para una compañía y el riesgo. En concreto, si definimos la rentabilidad en t para cada activo financiero i como $R_{t,i} = \frac{P_{t,i} - P_{t-1,i}}{P_{t-1,i}}$, donde el precio p está ajustado por dividendos, el modelo *CAPM* (Sharpe, 1964; Lintner, 1965) se define como:

$$E(R_i) - r_f = \beta_i (E(R_M) - r_f), \quad [1]$$

donde $E(R_i)$ representa la rentabilidad esperada del activo i , r_f es la rentabilidad del activo libre de riesgo, y $E(R_M)$ es la rentabilidad esperada del índice de mercado.

La ecuación [1] representa un modelo estadístico que reduce la dimensionalidad en los mercados (por ejemplo, miles de *stocks*) a través de un factor común. El parámetro β permite medir la sensibilidad de las rentabilidades de los activos frente al mercado. El factor común (rentabilidad del mercado, R_M) es capaz de explicar el 70 % de variabilidad en la sección cruzada del panel de rentabilidades. Este hecho marca el inicio de los *ETF* (*Exchange Traded Funds*) en los noventa. Pero, por otra parte, el modelo deja un 30 % de variabilidad no explicada, que puede ser explotada para tratar de batir al mercado.

El modelo de Fama-French de tres factores, Fama y French (1993, 1996), expande el modelo CAPM para tratar de reducir su variabilidad no explicada. Para ello, el modelo de Fama-French añade dos factores de riesgo nuevos: el factor valor y el factor tamaño. Esto es, este modelo incorpora el hecho de que, a lo largo del tiempo, las compañías pequeñas (baja capitalización bursátil) han batido al mercado de forma consistente (en comparación con las compañías grandes). Y de igual forma, las compañías baratas (alto valor contable respecto a su valor bursátil) han obtenido mejores rentabilidades que las compañías caras.

En concreto, el modelo calcula dos nuevos factores de la siguiente forma. El factor tamaño, *SMB* (*small minus big*), ordena para un periodo concreto, todas las acciones de empresas en el índice en función de su capitalización bursátil. Y crea una cartera que compra las acciones con mayor capitalización bursátil y vende aquellas con menor capital, calculando finalmente la rentabilidad de esa cartera en ese periodo. De igual forma, el factor valor, *HML* (*high minus low*), ordena para un periodo concreto, las empresas en función de la ratio valor contable/valor de mercado (*book to market*). A continuación se compran las acciones más baratas (mayor *book-to-market*) y se venden las más caras (menor *book-to-market*), y finalmente se calcula la rentabilidad de esa cartera en ese periodo.

El modelo de Fama-French de tres factores se define como:

$$R_{i,t} - r_{f,t} = \alpha_i + \beta_{M,i} (R_{M,t} - r_{f,t}) + \beta_{S,i} \text{SMB}_t + \beta_{H,1} \text{HML}_t + \varepsilon_{i,t}, \quad [2]$$

donde $R_{i,t}$ representa la rentabilidad de una acción/fondo/estrategia i en t , $r_{f,t}$ es la rentabilidad libre de riesgo en t , $R_{M,t}$ es la rentabilidad del mercado en t , SMB_t representa la rentabilidad del factor tamaño en t , y finalmente HML_t representa la rentabilidad del factor valor en t .

El modelo [2] es capaz de explicar más de un 90 % de variabilidad en la sección cruzada para carteras diversificadas. Los principales factores que explican la variabilidad entre rentabilidades son sensibles al mercado, al tamaño de la empresa, y a su valor (medido como la ratio *book-to-market*). Cualquier rentabilidad por encima de la esperada se atribuye, por

tanto a un riesgo no sistémico. La exposición al riesgo de cada empresa a cada uno de los tres factores se mide con el correspondiente parámetro β . Finalmente, el parámetro α mide el comportamiento de una empresa o estrategia (rentabilidad ajustada por riesgo): si es significativo, la rentabilidad obtenida no se explica solamente por estos factores comunes, sino que pueden existir otros (quizás específicos) que habría que considerar. Por tanto, el parámetro α resulta útil para saber si se bate al mercado, o para evaluar habilidades en gestión de fondos.

Por tanto, el modelo [2] explica una gran variabilidad en carteras diversificadas y permite calcular las rentabilidades ajustadas por riesgo (α) de una cartera o estrategia para evaluar su comportamiento respecto al mercado. Pero todavía presenta una variabilidad no explicada (alrededor del 10 %) que puede ser reducida introduciendo más factores de riesgo. Desde los años noventa, se han propuesto más y más factores de riesgo para reducir dicha variabilidad y además poder medir de forma más precisa las habilidades de un inversor (α).

Entre los factores de riesgo más conocidos, destacan (usando terminología inglesa, habitual en mercados financieros):

Cuadro 1.

Factores de riesgo más conocidos desde los años noventa

Firm size	Small stocks outperform large stocks
Value	High book-to-market ratio stocks outperform low book-to-market ratio stocks
Momentum	Winner stocks over the last 12 months outperform loser stocks
Investment	Conservative investment firms outperform aggressive investment firms
Profitability	Profitable firms outperform less profitable firms
Low volatility	Low volatility firms outperform high volatility firms

Los factores de riesgo del **cuadro 1** han sido capaces de batir al mercado (α significativa en largos periodos del pasado), pero tienen un comportamiento cíclico. Esto es, un factor de riesgo puede haber batido al mercado en un periodo de tiempo donde otro factor no ha sido capaz de hacerlo. La **figura 3** ilustra este comportamiento cíclico. Se puede observar cómo los factores de riesgo que batan al mercado en determinados años no son capaces de batirlo en años posteriores.

Desde los años noventa, cientos de artículos y factores de riesgo se han ido proponiendo, tratando de explicar aún más la variabilidad en la sección cruzada de las rentabilidades esperadas. En concreto, Harvey, Liu y Zhu (2016), analizan al menos 316 factores (anomalías) de la literatura que han batido al mercado de forma consistente, y concluyen que las anomalías que aparecen en los mercados son pequeñas, complejas, y dinámicas en el tiempo. Y muchas de ellas son consecuencia de p-valores significativos pero espurios, algo habitual cuando se realizan cientos de test de hipótesis para validar si una estrategia ha logrado batir al mercado en el pasado. La **figura 4** muestra la evolución del número de artículos y anomalías que han ido apareciendo en publicaciones científicas desde los años sesenta.

Figura 3.

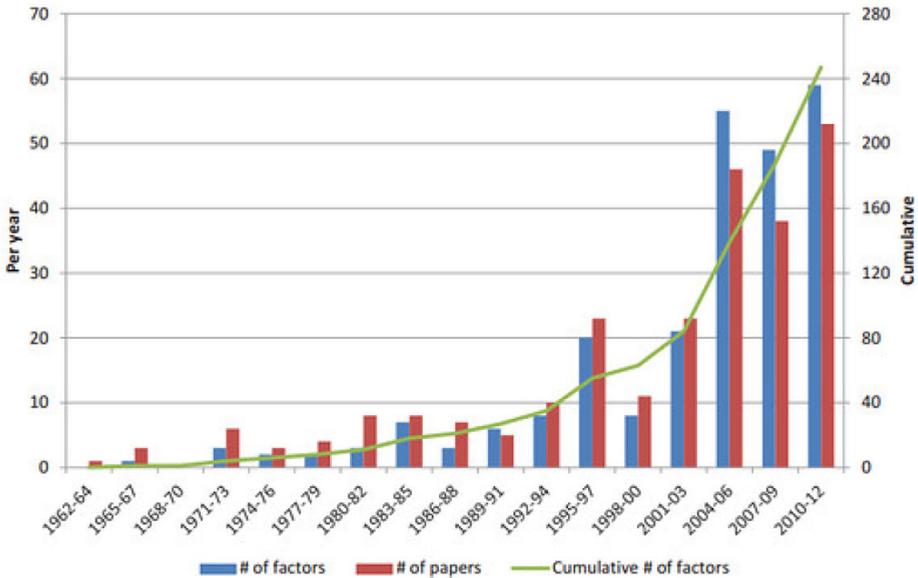
Naturaleza cíclica de los factores de riesgo



Fuente: ERI Scientific Beta.

Figura 4.

Evolución del número de anomalías y factores encontrados en la literatura académica



Fuente: Harvey, Liu y Zhu (2016).

Como se puede observar en la [figura 4](#), la propuesta de nuevas anomalías o factores crece considerablemente a partir de los años 2000. De hecho, el presidente de la American Finance Association en 2011, John Cochrane, llegó a decir en su discurso presidencial (John Cochrane, 2011): “financial academics and practitioners have created a zoo of factors. Most of the supposed market anomalies academics have identified don’t exist, or are too small to matter”. Por tanto, de los cientos de factores en el zoo, ¿cuáles son fruto del azar o de sesgos de selección?

Sí que hay ciertos factores de riesgo que parecen persistir a lo largo del tiempo, siendo los más conocidos: *beta*, *size*, *value*, *momentum*, *profitability*, *quality*, *term*, *carry* y *low volatility*. En todo caso, debido a que la ratio señal-ruido en los datos financieros es muy próximo a cero, cabe esperar que la predictibilidad futura de las rentabilidades (en base a datos pasados) sea escasa.

Es en este punto donde puede resultar muy conveniente el uso de herramientas avanzadas de estadística y de *machine learning*, con el objetivo de explotar al máximo la escasa predictibilidad observada en los mercados financieros. En concreto, estas herramientas tratan de identificar *a priori* los factores que batirán al mercado en el futuro en base a su comportamiento cíclico. Por tanto, es importante considerar una gran diversidad de factores para diversificar su exposición a los distintos periodos de tiempo y minimizar así el riesgo asociado. Además, estas herramientas permiten explotar no linealidades e interacciones entre los factores (predictores) y las rentabilidades futuras de las compañías. Finalmente, las herramientas avanzadas de estadística y de *machine learning* pueden presentar problemas de sobreajuste, es decir, son capaces de predecir bien el pasado pero mal el futuro. Es, por tanto, necesario saber manejar bien dichas herramientas para mitigar este problema.

En la siguiente sección se repasarán las herramientas más avanzadas capaces de explotar la baja predictibilidad en los mercados financieros.

3. METODOLOGÍA DE *MACHINE LEARNING*

Las herramientas de *machine learning* ponen el énfasis en reducir el error de predicción de rentabilidades futuras, mientras que los modelos estadísticos tratan de explicar las diferencias entre rentabilidades pasadas. En concreto, el siguiente modelo estadístico es una extensión del modelo factorial [2]:

$$R_{i,t} = \alpha_i + \beta_i^T f_t + \varepsilon_{i,t} \quad [3]$$

donde $R_{i,t}$ representa las rentabilidades de (miles) de compañías, y f_t son (cientos) de factores (predictores) que explican las rentabilidades de forma lineal. Es un enfoque explicativo porque las relaciones se analizan en el mismo tiempo t .

En cambio, el enfoque de *machine learning* es predictivo, y consiste en desplazar una posición el tiempo en el modelo anterior:

$$R_{t+1,i} = \alpha_i + \beta_i^T f_t + \varepsilon_{t+1,i} \quad [4]$$

Este desplazamiento temporal implica que el enfoque de *machine learning* no pueda conseguir una predictibilidad superior al 2 %, mientras que el enfoque estadístico puede explicar más de un 90 % de variabilidad.

La cuestión importante que surge ahora es: ¿será posible batir al mercado con menos de un 2 % de predictibilidad?

En primer lugar repasemos qué herramientas analíticas son capaces de conseguir una predictibilidad del 2 %. Posteriormente veremos cómo se pueden diseñar estrategias de inversión a partir de predicciones poco precisas.

Las herramientas de Ciencia de Datos engloban tanto modelos avanzados de estadística como algoritmos de *machine learning*, y son aptas para tratar de predecir variables en grandes conjuntos de datos (*big data*). En concreto, las herramientas avanzadas de estadística tratan de estimar el modelo [4] asumiendo una relación lineal entre los factores (predictores) y la respuesta (rentabilidades). Como la cantidad de rentabilidades a predecir en cada instante t es muy elevada (orden de miles) y la cantidad de factores también (orden de cientos), se requieren herramientas avanzadas capaces de estimar bien dicho modelo tratando de evitar problemas de sobreajuste. Las mejores herramientas de estadística son extensiones de mínimos cuadrados, donde bien se añaden términos de regularización para reducir el sobreajuste (Lasso, Elastic Net), o bien se trata de reducir la dimensionalidad de los factores (PCR, PLS).

Por otro lado, las herramientas de *machine learning* tratan de relajar la hipótesis de linealidad en el modelo [4], y capturar así posibles no-linealidades e interacciones entre factores. Por tanto, en lugar de estimar el modelo [4] de forma explícita, estas herramientas entrenan una función no explícita en su lugar: $R_{t+1} = \text{map}(f_t) + \varepsilon_{t+1}$. Entre las herramientas de *machine learning* para este tipo de datos destacan: combinaciones de árboles de decisión (*random forests* y *gradient boosting*), y las redes neuronales.

Finalmente, hay que mencionar que para capturar la naturaleza dinámica en los mercados financieros, los modelos anteriores se reentrenan cada cierto tiempo (cada mes o cada año). En la siguiente sección veremos cómo estas herramientas son capaces de capturar parte de la escasa predictibilidad presente en los mercados financieros. Pero una vez capturada esta predictibilidad, ¿cómo se pueden diseñar estrategias de inversión que exploten bien las predicciones para tratar de batir al mercado?

En principio se pueden diseñar muchas estrategias de inversión automáticas, con cierto sentido de optimalidad. Markowitz (1952) propuso una estrategia de diversificación óptima teniendo en cuenta las rentabilidades esperadas de cada compañía, y la matriz de covarianzas asociada a ellas. En nuestro contexto, parece inviable calcular la matriz de correlaciones entre miles de rentabilidades de distintas compañías. Una estrategia más factible en la práctica consiste en diversificar entre las distintas compañías usando solamente la información

de las rentabilidades obtenidas mediante las herramientas de Ciencia de Datos anteriores. En concreto, y dado un mes determinado, se pueden ordenar todas las compañías en base a sus predicciones para el próximo mes. Una vez ordenadas, se pueden comprar las compañías con predicciones más altas (aquellas por encima del percentil 90 %) y vender (o descartar) aquellas con predicciones más bajas (aquellas por debajo del percentil 10 %). Para comprar o vender compañías se pueden usar los mismos pesos para todas ellas y así simplificar aún más la estrategia.

En la siguiente sección se muestra la aplicación de estas ideas en el mercado de EE. UU. donde se realiza un *backtesting* de distintas estrategias desde 1960 a 2016, considerando un total de 30.000 compañías en ese periodo, con una media de unas 6.000 rentabilidades a predecir cada mes. Además, se consideran alrededor de 100 características de cada compañía (factores), decenas de variables macroeconómicas, más sus posibles interacciones: en total, alrededor de 1000 predictores cada mes.

4. APLICACIÓN: *EMPIRICAL ASSET PRICING VÍA MACHINE LEARNING, REVIEW OF FINANCIAL STUDIES, 2020*

La siguiente aplicación está extraída de Gu, Kelly y Xiu (2020). Es este artículo, los autores realizan una comparación exhaustiva de diferentes herramientas de estadística avanzada y de *machine learning* para medir la ganancia económica de las mismas. A continuación se muestra un esquema del *backtesting* realizado en el artículo.

Para cada mes t , desde el año 1987 a 2016:

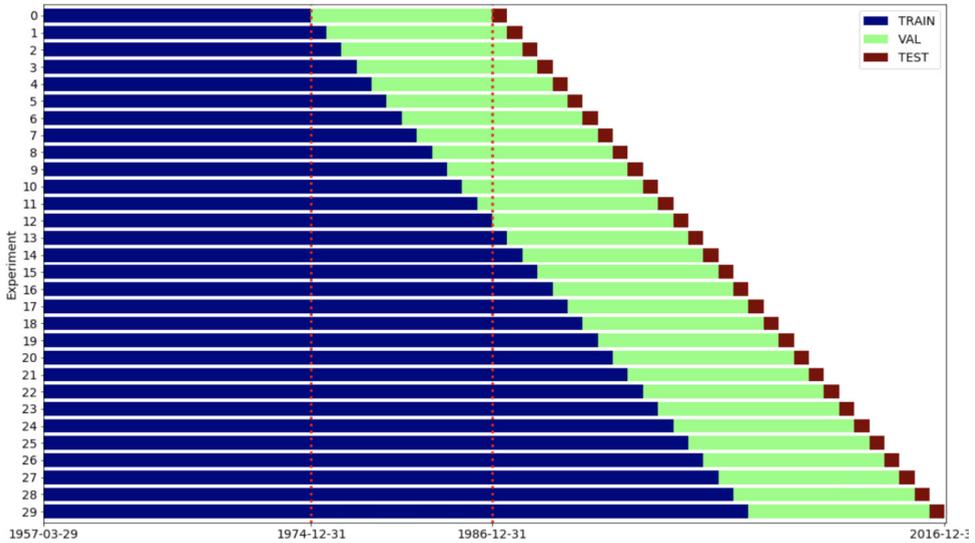
- Se estiman distintos modelos estadísticos y de ML, explicados en la sección anterior, usando el conjunto de predictores (factores). Estos modelos utilizan información de los 30 años inmediatamente anteriores (más de 18 años para entrenamiento, y 12 años para su validación).
- Una vez los modelos han sido entrenados con información previa, se usan para predecir la rentabilidad en el $t + 1$ para todas las compañías disponibles en ese mes.
- Se ordenan, de mayor a menor, todas las predicciones del paso anterior, y se desarrolla la siguiente estrategia de inversión: comprar las compañías en el percentil 10 % superior de las predicciones (con el mismo peso) y vender las compañías en el percentil 10 % inferior.
- Finalmente, se evalúa el comportamiento estadístico y económico en $t + 1$ de todas las herramientas consideradas.

Cabe destacar que, debido a que las herramientas de ML tienen un alto coste computacional, dichas herramientas se reentrenan (en el Paso 1) cada doce meses.

En la **figura 5** se ilustra el *backtesting* propuesto en Gu, Kelly y Xiu (2020).

Figura 5.

Esquema de *backtesting*



Fuente: Gu, Kelly y Xiu (2020).

En color azul se muestran los meses utilizados para entrenar los modelos. Se comienza con 18 meses, y luego se va añadiendo un mes según avanza el *backtesting*. En color verde se muestra la ventana de validación (donde se optimizan hiperparámetros presentes en las herramientas de ML), que consta siempre de 12 meses. Finalmente, en color rojo aparece el mes a predecir en el Paso 2 del esquema anterior. En total, el *backtesting* consta de 30 meses donde se realizan predicciones (muestra test).

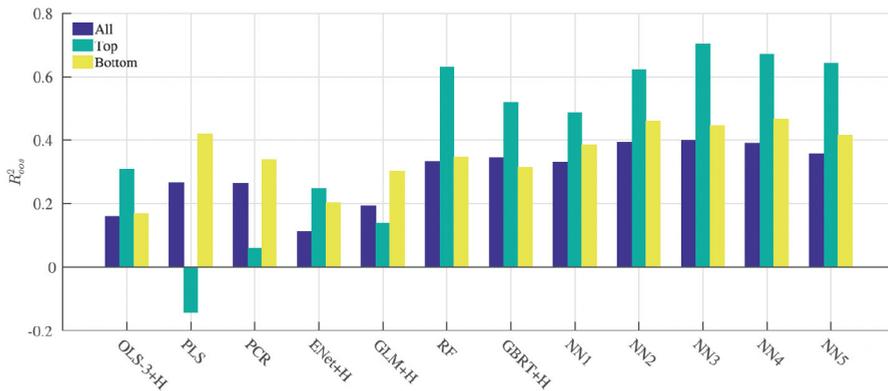
La **figura 6** muestra la comparación de las distintas herramientas consideradas (13 en total) en términos del R^2 obtenido en el periodo de test (*out-of-sample*), que es una medida de precisión de las predicciones.

En concreto, el cuadro muestra el comportamiento de distintas herramientas analíticas: *OLS* (*ordinary least squares*) es una regresión lineal considerando todos los factores disponibles, *OLS-3* es la misma regresión, pero considerando solamente los 2 factores de Fama-French (tamaño y valor) y el factor *momentum*, *PLS* (*partial least squares*) es una variante de regresión lineal que proyecta conjuntamente los predictores y la variable respuesta en un nuevo espacio, *PCR* (*principal component analysis*) es una regresión lineal considerando las primeras componentes principales de los predictores, *ENet* (*elastic net*) representa una versión regularizada de regresión lineal, *GLM* (*generalized linear model*) es una extensión no

Figura 6.

Comportamiento estadístico de las distintas herramientas

	OLS +H	OLS-3 +H	PLS	PCR	ENet +H	GLM +H	RF	GBRT +H	NN1	NN2	NN3	NN4	NN5
All	-3.46	0.16	0.27	0.26	0.11	0.19	0.33	0.34	0.33	0.39	0.40	0.39	0.36
Top 1,000	-11.28	0.31	-0.14	0.06	0.25	0.14	0.63	0.52	0.49	0.62	0.70	0.67	0.64
Bottom 1,000	-1.30	0.17	0.42	0.34	0.20	0.30	0.35	0.32	0.38	0.46	0.45	0.47	0.42



Fuente: Gu, Kelly y Xiu (2020).

lineal de la regresión múltiple, *RF* (*random forest*) representa una combinación de árboles de decisión, *GBRT* (*gradient boosted regression trees*) representa otra combinación de árboles pero de forma secuencial, y finalmente *NN* (*neural network*) son distintas arquitecturas de redes neuronales considerando desde una capa hasta cinco (NN1, . . . , NN5).

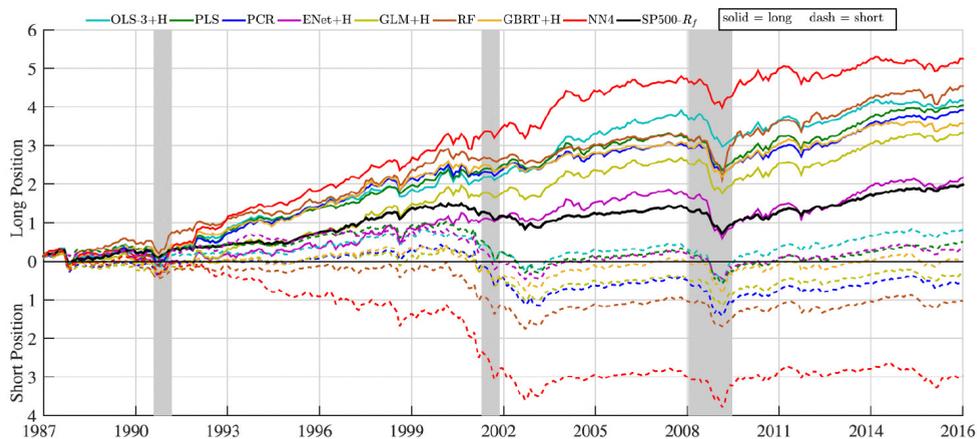
La primera fila del cuadro en la figura 6 muestra cómo herramientas tradicionales (OLS) obtienen una muy baja precisión (R^2 negativo o muy próximo a 0). Las herramientas basadas en estadística avanzada (PLS, PCR, ENet y GLM) consiguen mejorar la precisión, llegando a obtener un R^2 alrededor de 0,27 %. Pero las herramientas de ML (RF, GBRT, NN) consiguen aumentar más la precisión, llegando a obtener un $R^2 = 0,4$ en el caso de las redes neuronales (NN). Estos resultados indican el valor de incorporar interacciones complejas entre los predictores, que son capturadas por las herramientas de ML, y en menor medida por las de estadística.

En resumen, el R^2 (*out of sample*) es menor del 1 % para las herramientas de ML más avanzadas (muy baja predictibilidad). Sin embargo, la figura 7 muestra cómo la estrategia de inversión (Paso 3 en el *backtesting*) es capaz de explotar esta baja predictibilidad para conseguir un buen rendimiento económico.

En concreto, la figura 7 muestra la rentabilidad acumulada de las distintas estrategias de inversión (con las posiciones cortas y largas), e incluye como *benchmark* (en color negro)

Figura 7.

Comportamiento económico de las distintas herramientas



Fuente: Extraído de Gu, Kelly y Xiu (2020).

la rentabilidad acumulada del índice de mercado (S&P500). Se observa cómo las estrategias basadas en redes neuronales (especialmente NN4, en color rojo) dominan claramente al resto de estrategias. Más concretamente, las herramientas avanzadas de estadística baten al mercado ligeramente, mientras que las basadas en ML logran batirlo de forma más clara, siendo los modelos basados en redes neuronales los más prometedores: obtienen *Sharpe ratio* anualizado (rentabilidad anual entre volatilidad) de 2.45, y *alphas* significativamente positivos.

En resumen, las herramientas avanzadas de ML consiguen explotar la escasa predictibilidad existente para obtener una alta ganancia en términos económicos.

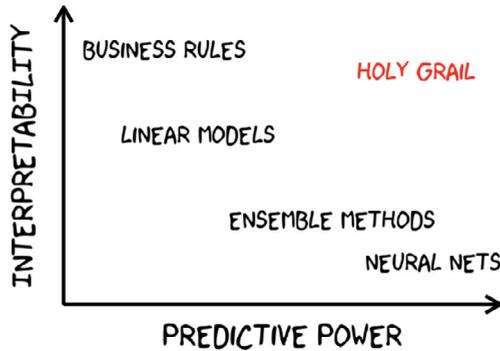
5. INTERPRETABILIDAD DE LAS HERRAMIENTAS DE MACHINE LEARNING

Las herramientas de *machine learning*, debido a que estiman el modelo $R_{t+1} = \text{map}(f_t) + \varepsilon_{t+1}$ de forma no explícita, no resultan adecuadas para entender de qué forma los factores (predictores) ayudan a explotar mejor la predictibilidad. Pero en los últimos años han ido apareciendo herramientas que ayudan a entender mejor estas relaciones. En particular, las herramientas de interpretabilidad en *machine learning* analizan la importancia de cada variable en las predicciones obtenidas, así como ayudan a entender mejor las relaciones entre los predictores, y cómo dichas relaciones evolucionan con el tiempo.

En general, cuanto más poder predictivo tiene un modelo, menor es su capacidad interpretativa, como muestra la *figura 8*.

Figura 8.

Capacidad predictiva de modelos vs. interpretabilidad

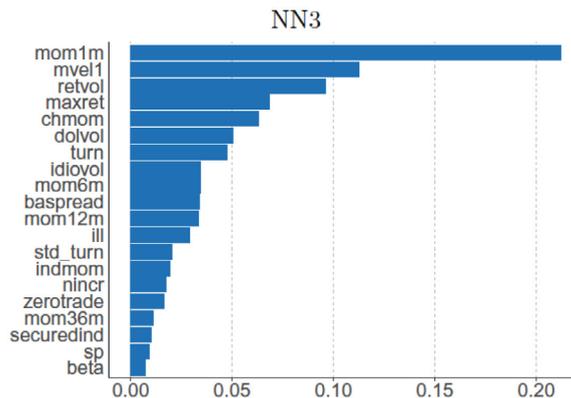


Fuente: @ManoMano.

En la aplicación financiera de la sección anterior, las herramientas de interpretabilidad analizan la importancia de cada factor considerado para cada modelo. La importancia se mide en términos de mejora del error de predicción para cada factor considerado. Además, estas herramientas ayudan a entender la relación marginal (no lineal) entre un factor y las predicciones de las rentabilidades. La figura 9 muestra la importancia de los 20 predictores más importantes para uno de los mejores modelos predictivos (red neuronal de tres capas). La importancia de las variables se ha normalizado para que sume 1 y sea más fácil su interpretación.

Figura 9.

Importancia de los predictores en la respuesta

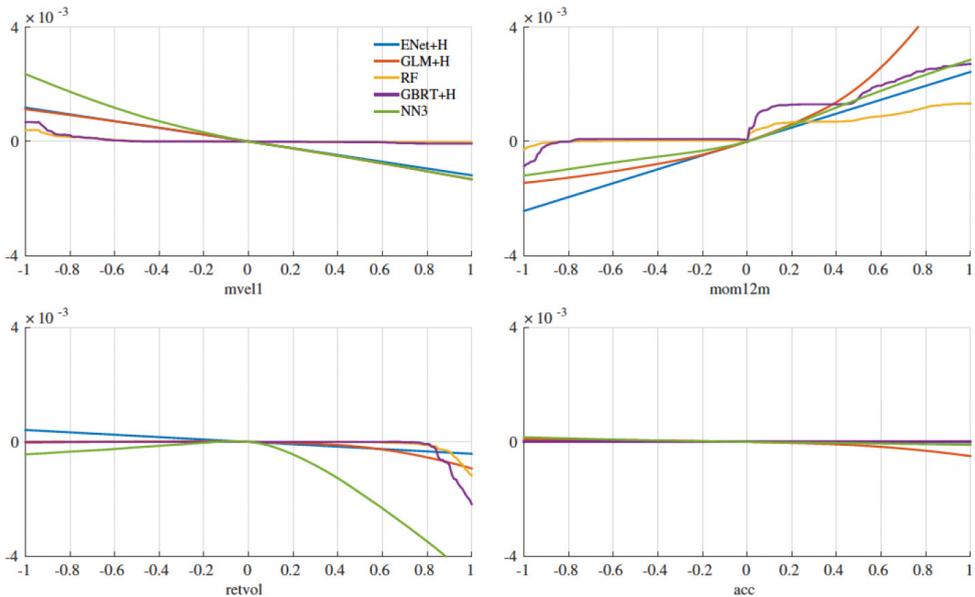


Fuente: Gu, Kelly y Xiu (2020).

De la **figura 9** se deduce que los predictores dominantes para ese modelo están relacionados con *momentum*, liquidez y volatilidad. La **figura 10** muestra el impacto marginal (para cada modelo) de un factor sobre las rentabilidades. Este impacto se consigue medir (para un predictor) asumiendo que el resto de predictores permanece fijo. La figura muestra, para distintos modelos, el impacto marginal de 4 de los factores más importantes. En modelos lineales, este impacto sería lineal.

Figura 10.

Efecto marginal de un predictor en la respuesta



Fuente: Gu, Kelly y Xiu (2020).

En concreto, la **figura 10** identifica patrones no lineales en términos de predictibilidad, que los modelos lineales no son capaces de capturar, o los identifican con un efecto nulo. La figura superior izquierda muestra que los retornos esperados decrecen con el tamaño para los modelos basados en *machine learning*, mientras que los modelos estadísticos no encuentran relación. La figura superior derecha muestra que los retornos actuales son crecientes con los retornos encontrados en los últimos doce meses, pero las herramientas de *machine learning* logran modelar dicho crecimiento de forma no lineal. Algo similar ocurre en la figura inferior izquierda, donde las herramientas de *machine learning* logran capturar una relación decreciente no lineal entre los retornos y su volatilidad. Finalmente, la figura inferior derecha muestra que todos los modelos apenas encuentran relación entre los retornos y los devengos.

Estas relaciones no lineales explican parcialmente por qué las herramientas de *machine learning* son capaces de predecir algo mejor que las herramientas avanzadas de estadística.

6. CONCLUSIONES

En este trabajo se ha analizado si es posible diseñar estrategias de inversión basadas en *big data* y en *machine learning* para tratar de conseguir mejores rentabilidades (por unidad de riesgo) que los índices representativos de los mercados financieros. La principal conclusión es que sí es posible aunque no es sencillo, debido a que la predictibilidad futura de las rentabilidades (en base a datos pasados) es muy pequeña. Esto es, en los mercados financieros la ratio señal-ruido de los datos es muy baja. Pero los resultados mostrados en la aplicación de este trabajo muestran que pequeñas mejoras en las predicciones pueden dar lugar a grandes mejoras en las rentabilidades, explotando interacciones y no linealidades presentes en los datos para incrementar el valor económico. En concreto, las herramientas de *machine learning*, usando como *input* un gran volumen de datos sobre miles de compañías y variables macroeconómicas son capaces de explotar un escaso 1 % de predictibilidad existente, y conseguir así un alto rendimiento económico (*Sharpe ratio* anualizado superior a 2 a lo largo de 30 meses).

Por tanto, las herramientas de *machine learning* resultan ser muy prometedoras para predecir miles de rentabilidades futuras en los mercados financieros. Además, las recientes herramientas de interpretabilidad de estas herramientas tratan de intuir el impacto (no lineal) de los predictores en la respuesta a lo largo del tiempo.

La evidencia empírica de este trabajo está basada en el análisis de Gu, Kelly y Xiu (2020) en el mercado de acciones de EE. UU. En DeMiguel *et al.* (2022) se presenta una evidencia empírica similar en fondos de inversión de EE. UU., mostrando la robustez de las herramientas de *machine learning* en distintos mercados.

Referencias

- COCHRANE, J. (2011). Presidential address: Discount rates. *Journal of Finance*, 66, pp. 1047–1108.
- DEMIGUEL, V., GIL-BAZO, J., NOGALES, F. J. y SANTOS, ANDRÉ A. P. (2022). Machine Learning and Fund Characteristics Help to Select Mutual Funds with Positive Alpha. *WP*.
- FAMA, E. F. y FRENCH, K. R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, 33, pp. 3–56.
- FAMA, E. F. y FRENCH, K. R. (1996). Multifactor Explanations of Asset Pricing Anomalies. *Journal of Finance*, 51, pp. 55–84.
- GU, S., KELLY, B. y XIU, D. (2020). Empirical Asset Pricing via Machine Learning. *Review of Financial Studies*, 33, pp. 2223–2273.
- HARVEY, C. R., LIU, Y. y ZHU, H. (2015)... and the cross-section of expected returns. *Review of Financial Studies*, 29, pp. 5–68.
- LINTNER, J. (1965). The Valuation of Risk Assets and the Selection of Risky Investments in Stock Portfolios and Capital Budgets. *Review of Economics and Statistics*, 47, pp. 13–37.

CAPÍTULO IV: ¿Es posible batir a los mercados financieros usando herramientas de *big data* y de *machine learning*?

MACLEAN, D. y PONTIFF, J. (2016). Does Academic Research Destroy Stock Return Predictability? *Journal of Finance*, 71, pp. 5–32.

MARKOWITZ, H. (1952). Portfolio Selection. *Journal of Finance*, 7(1), pp. 77– 91.

SHARPE, W. F. (1964). Capital Asset Prices: A Theory of Market Equilibrium under Conditions of Risk. *Journal of Finance*, 19, pp. 425– 42.

CAPÍTULO V

Aprendizaje profundo para series temporales en finanzas: aplicación al factor *momentum*

Iván Blanco*

Sergio J. García

Álvaro Remesal

Este trabajo demuestra la capacidad predictiva de las redes neuronales recurrentes *Long Short-Term Memory (LSTM)* para predecir series temporales financieras. Las arquitecturas *LSTM* son herramientas de predicción de secuencias de datos con escasa implantación hasta ahora en el ámbito académico de las finanzas. Nuestra aplicación de las redes *LSTM* al factor momentum genera predicciones con R^2 fuera de la muestra y ganancias en términos económicos que son superiores al 2 %. Los resultados demuestran el poder predictivo de los modelos *LSTM* y sirven como punto de partida para analizar de manera más exhaustiva series temporales financieras mediante estas arquitecturas.

Palabras clave: machine learning, deep learning, redes neuronales recurrentes, momentum.

* Agradecemos a Santiago Carbó, Juan José Ganuza, Daniel Peña y Pilar Poncela por la invitación para elaborar este capítulo y a los participantes de las Jornadas Funcas sobre Análisis Financiero y Big Data por sus comentarios. Álvaro Remesal ha obtenido financiación por parte del proyecto PID2021-128994NA-I00 durante la elaboración de este trabajo.

1. INTRODUCCIÓN

La tarea de predicción de la rentabilidad de los activos financieros, es decir, determinar cuándo y por qué distintos activos financieros tienen distintas rentabilidades, se remonta a los mismos orígenes del estudio de las finanzas (Bachelier, 1900; Granger y Morgenstern, 1970, Fama *et al.*, 1969). Las diferentes teorías sobre la eficiencia de los mercados financieros sugieren que cualquier tarea de predicción de rentabilidad es un ejercicio fútil. La teoría del Paseo Aleatorio implica que la rentabilidad de los activos financieros no puede predecirse en función de su rentabilidad pasada (Fama, 1970). A su vez, las teorías de equilibrio con arbitraje suponen que el rendimiento esperado de un activo financiero solamente refleja su exposición a fuentes de riesgo sistemáticas (no diversificables) (Ross, 1976).

No obstante, la literatura académica en finanzas, con una atención especial a la rentabilidad en el mercado bursátil, ha generado una multitud de estudios sobre la potencial existencia de variables que permiten predecir la rentabilidad de los activos financieros (*e.g.*, Campbell y Shiller, 1983; Fama y French, 1993; Fama y French, 2015; Harvey, Liu y Zhu, 2016; McLean y Pontiff, 2016; Hou, Xue y Zhang, 2020). En muchos casos, estos resultados sugieren la existencia de oportunidades de inversión rentables al alcance de cualquier inversor, que generan altos niveles de rentabilidad ajustada al riesgo asumido, dando lugar a multitud de hipótesis sobre sesgos conductuales para explicar las anomalías observadas¹.

En este estudio describimos un modelo general y no lineal para series temporales basado en redes neuronales profundas con el objeto de predecir la rentabilidad de una de las estrategias más estudiadas en el mundo de las finanzas: *momentum*. Esta estrategia hace referencia a una anomalía, ampliamente documentada empíricamente, que indica que los activos que han tenido mejores (peores) retornos en el pasado tienden a tener mejores (peores) retornos también en el futuro. El uso de técnicas de aprendizaje automático (*machine learning*) como las redes neuronales profundas permite, de modo natural, asimilar las dinámicas complejas y específicas que subyacen a la rentabilidad de esta estrategia de inversión. Los resultados de la estimación muestran que el modelo basado en redes neuronales profundas tiene una capacidad predictiva fuera de la muestra (*out-of-sample*) significativa en términos estadísticos y económicos. Los resultados ilustran la relevancia de dinámicas no lineales que difícilmente pueden capturarse en modelos econométricos tradicionales.

El modelo predictivo presentado en este estudio está basado en técnicas de *machine learning* aplicadas a datos en los que existe una relación secuencial entre observaciones, en este caso una relación temporal. De manera específica, el modelo predictivo utiliza una arquitectura de redes neuronales *Long Short-Term Memory (LSTM)* que trata de capturar de manera flexible las relaciones no lineales entre las rentabilidades pasadas y futuras. Además de otras ventajas computacionales, la arquitectura *LSTM* es capaz de “guardar” información remota en el tiempo que la propia red identifica como relevante a la hora de predecir la evolución temporal de una serie.

¹ Análisis teóricos en este sentido son los trabajos de Daniel *et al.* (1998), Hong y Stein (1999), Hirshleifer y Luo (2001) o Alti y Titman (2019), entre otros muchos.

Este estudio, por tanto, ofrece dos contribuciones. En primer lugar, presenta un modelo predictivo que puede capturar la predictibilidad de la serie temporal de la rentabilidad diaria del factor *momentum*. Es decir, desarrollamos un modelo lo suficientemente general para poder predecir la persistencia en la rentabilidad de los activos financieros. En segundo lugar, aplica de manera novedosa en la literatura académica de finanzas las arquitecturas *LSTM* de redes neuronales profundas para la predicción de series temporales. Las redes *LSTM*, propuestas inicialmente por Hochreiter y Schmidhuber (1997), están diseñadas para descubrir de modo flexible patrones “ocultos” en las series temporales con interacciones no lineales. Este tipo de arquitectura de predicción de datos se encuentra entre las arquitecturas con mayor éxito a nivel comercial dentro de la inteligencia artificial, siendo aplicadas para el reconocimiento automático de voz (como Siri o Alexa). No obstante, el uso de estas arquitecturas hasta ahora ha sido escaso en el ámbito académico de las finanzas.

A nivel general, los ejercicios de predicción de rentabilidades en la sección cruzada (*cross section*) se basan en aproximar la esperanza condicionada de las rentabilidades en base a una o varias características:

$$\mathbb{E} [r_{t,t+1}|x_t] = F(x_t) \quad [1]$$

donde $F(\cdot)$ es una función que transforma características, x_t , de los activos en un periodo t en una predicción de su rentabilidad en el siguiente periodo. Por su parte, $r_{t,t+1}$, representa la rentabilidad obtenida entre el instante t y el instante $t + 1$. En este ejercicio de predicción queremos entender si los activos con valores altos de ciertas características generan rentabilidades distintas frente activos con valores bajos de esas mismas características.

Las características predictivas, x_t , bien pueden ser variables que reflejan, entre otros, las distintas exposiciones a las fluctuaciones del mercado, los distintos tamaños de las empresas, o diferentes ratios de valoración que combinan precios de mercado y variables contables. A su vez, las características incluidas en x_t bien pueden ser las rentabilidades pasadas del activo, $x_t = r_{t-h,t}$, donde h puede ser un horizonte temporal arbitrario y, por tanto, $r_{t-h,t}$ representa la rentabilidad entre el instante $t-h$ y el instante t . Precisamente, desde Jegadeesh y Titman (1993), una amplia literatura ha analizado la existencia de *momentum*, o inercia, en la rentabilidad de los activos financieros en el medio plazo. Los activos que han generado una rentabilidad relativamente alta en el pasado reciente tienden a generar una rentabilidad relativamente alta en el medio plazo. Y al contrario, activos con una rentabilidad relativamente baja en el pasado reciente tienden a generar una rentabilidad relativamente baja en el medio plazo². Este tipo de predictibilidad supone uno de los mayores desafíos a las teorías de eficiencia de los mercados.

Multitud de análisis empíricos han verificado la generalidad de la anomalía *momentum* debido a su amplia presencia en múltiples activos financieros, múltiples periodos de tiempo y por su robustez en múltiples análisis estadísticos. Con mucha frecuencia, los modelos explica-

² Además, esa relación se revierte en el largo plazo. Los activos “ganadores” pierden parte de su valor en el largo plazo, al contrario que los activos “perdedores” (Jegadeesh y Titman, 1993).

tivos del rendimiento de los activos financieros suelen incorporar un factor *momentum* para tener en cuenta la aparente y mecánica persistencia de la rentabilidad, aunque siga habiendo un amplio debate académico sobre los orígenes e interpretación de esta anomalía (Fama y French, 2015; Cochrane, 2007).

La existencia de *momentum* da lugar a estrategias de inversión, en principio rentables, basadas en la explotación de la persistencia en la rentabilidad. Es decir, supongamos que en cada momento de tiempo construimos una cartera que adquiere el 10 % de las acciones con mayor rentabilidad en un horizonte temporal pasado h (esta cartera la denominamos como $d1$), $r_{t-h,t}^{d1}$, y vende en corto el 10 % de las acciones con menor rentabilidad en ese mismo horizonte (esta cartera la denominamos como $d10$), $r_{t-h,t}^{d10}$, donde h puede ser, por ejemplo, 12 meses. La literatura empírica ha mostrado que la rentabilidad de esta cartera, $r_{t,t+s}^{Mom}$, es sustancialmente positiva para periodos de inversión, s , de entre 6 y 18 meses.

La media obtenida en los estudios empíricos de la rentabilidad de la estrategia *momentum*, representada por la serie temporal $r_{t,t+s}^{Mom}$, es significativamente alta. No obstante, debido a que la cartera *momentum* tiene una composición que varía en el tiempo, las dinámicas de esa persistencia tienen características particulares. En primer lugar, la serie temporal es predecible en función de su pasado (Huang, 2022). En particular, la autocorrelación de $r_{t,t+1}^{Mom}$ es negativa. En segundo lugar, la trayectoria pasada de la serie es importante. Por ejemplo, en la sección cruzada, las series con menos cambios repentinos tienden a mostrar mayor predictibilidad (Da *et al.*, 2014). Además, la persistencia en la rentabilidad es mayor en aquellos activos que acumulan mayor rentabilidad en el periodo más reciente (Blanco *et al.*, 2023).

Por último, la tercera característica propia de la anomalía *momentum* es que la estrategia está sujeta a rentabilidades negativas extremas (*crashes*) (Barroso y Santa Clara, 2015; Daniel y Moskowitz, 2016). Con relativa frecuencia hay periodos en los que la cartera de activos “ganadores” muestra un rendimiento marcadamente inferior a la cartera de activos “perdedores”. Esto suele ocurrir cuando la cartera de “perdedores” de manera súbita experimenta una reversión en su rentabilidad. La existencia de estos *crashes* reduce el atractivo de la estrategia *momentum* y puede explicar la existencia de una rentabilidad extraordinaria, o “alfa”. No obstante, estrategias *momentum* que ajustan la inversión por el nivel pasado de volatilidad de los componentes de la cartera tienden a salir indemnes de estos periodos con rentabilidades negativas extremas.

Este tipo de características específicas sugieren la existencia de no-linealidades relevantes en la dinámicas de *momentum*. No obstante, cada una de estas características se ha estudiado de manera separada. La cuestión es, por tanto, si podemos obtener un modelo predictivo que, de manera flexible, sea capaz de incorporar todos estos aspectos y permita obtener una predicción de la rentabilidad de la estrategia *momentum*. Concretamente, queremos saber si es viable predecir el grado de persistencia en la rentabilidad de los activos financieros o, en otras palabras, si podemos predecir hasta qué punto la rentabilidad pasada de la cartera *momentum* supone una señal informativa de su rentabilidad futura.

En este estudio, mediante la aplicación de arquitecturas *LSTM*, hacemos frente a la tarea de predecir la serie temporal de rentabilidad diaria de *momentum* capturando su complejo comportamiento. De un modo general, nuestra tarea de predicción se resume en la estimación de una función H tal que:

$$r_{t,t+s}^{Mom} = H(x_{t-1}, \dots, x_{t-K}) + \varepsilon_t \quad [2]$$

Donde cada uno de los argumentos $\{x_{t-j}\}_{j=1}^K$ es un vector con información sobre la rentabilidad de los activos que conforman la cartera *momentum* en diferentes horizontes pasados y ε_t es un término de error.

Los resultados de nuestro análisis muestran una capacidad predictiva de los modelos *LSTM* superiores al 0,5 % en términos de R^2 , que también implican ganancias de utilidad económicamente relevantes del uso del modelo propuesto respecto a una predicción solamente basada en la media histórica (Campbell y Thompson, 2008). De entre todos los modelos explorados, el mayor poder predictivo está generado por el modelo que solamente utiliza información sobre las series de rentabilidades de las carteras *momentum* a un día y a 120 días.

Las ganancias de predicción son significativas en términos estadísticos y también en términos económicos. Un inversor con preferencias media-varianza estaría dispuesto a pagar alrededor de un 2 % de su riqueza, anualmente, por acceder a una estrategia basada en el modelo que mejor predice la serie temporal del factor *momentum*, en comparación con una estrategia que utiliza la media histórica para predecir la rentabilidad. Esto es, la predicción con arquitectura *LSTM* es capaz de capturar de manera notable las no-linealidades intrínsecas al factor *momentum* sin que esto implique mayor riesgo.

Todos los diferentes modelos analizados generan predicciones que, en muchos periodos, no muestran gran variación respecto a la rentabilidad observada del factor *momentum*. No obstante, los modelos tienden a predecir con mucha precisión los periodos en los que se producen rentabilidades negativas extremas en el factor *momentum*, que suelen estar marcados por episodios de alta volatilidad. Por tanto, observamos empíricamente cómo los modelos *LSTM* encuentran estrategias de inversión que son capaces de anticipar las rentabilidades negativas extremas, *crashes*, y generar ratios de Sharpe³ del orden de 0,5.

La investigación en finanzas cada vez hace un mayor uso de técnicas de aprendizaje automático para analizar bases de datos masivas (*big data*). Uno de los desafíos fundamentales de los ejercicios de predicción en series temporales de rentabilidad es la proporción excesiva de ruido³ que contienen estas series temporales en relación a la información relevante sobre la rentabilidad esperada de un activo. Esto es, los precios de los activos financieros incorporan información y se mueven por múltiples motivos que no están relacionados con su verdadera rentabilidad esperada. Por tanto, la tarea fundamental para cualquier modelo de

³ La ratio de Sharpe se define como la rentabilidad en exceso sobre el activo libre de riesgo entre la volatilidad de la rentabilidad de la estrategia.

predicción de rentabilidad, y en el caso particular de este estudio basado en la arquitectura *LSTM*, consiste en aglutinar de manera eficiente la información relevante para predecir la rentabilidad esperada del factor *momentum*.

La literatura académica, hasta el momento, se ha ocupado principalmente de explotar herramientas de aprendizaje automático como método de selección de predictores de la rentabilidad entre una amplia variedad de candidatos. Rapach *et al.* (2013) representa el primer análisis que introduce herramientas específicas de *machine learning*, en este caso una estimación LASSO, a la predicción de rentabilidades financieras. Chincó *et al.* (2019) también utilizan la estimación LASSO para la predicción de rentabilidades minuto a minuto. Gu *et al.* (2018) emplean una lista exhaustiva de herramientas de aprendizaje automático para analizar la predictibilidad de la rentabilidad de las acciones. Kozak *et al.* (2020) también explotan la metodología LASSO para, desde un punto de vista bayesiano, seleccionar entre múltiples características aquellas que determinan el factor estocástico de descuento. Han *et al.* (2019) proponen procedimientos para predecir las rentabilidades en la sección cruzada entre más de cien características⁴.

Los estudios anteriores se centran en la predictibilidad en la sección cruzada, esto es, en las diferencias entre activos que predicen las diferencias en rentabilidades. Otra línea de investigación parte de la literatura que explora la predictibilidad de la rentabilidad del mercado en su conjunto a través de una serie de indicadores económicos y financieros como ratios de valoración, tipos de interés, o inflación⁵. Moskowitz *et al.* (2012) muestran que carteras formadas por activos con rentabilidad pasada positiva generan rentabilidades extraordinarias, aunque la significatividad de estos resultados es disputada por Huang *et al.* (2020). Rapach y Zhou (2019) aplican el método de selección de Han *et al.* (2019) para predecir la rentabilidad del mercado. Fama y French (2020) sugieren utilizar los coeficientes sobre los factores sistemáticos estimados en la sección cruzada como factores en la serie temporal para ajustar los modelos de valoración. Engelberg *et al.* (2021) muestran que las características medias de los factores en la sección cruzada no pueden predecir la rentabilidad de mercado.

El artículo de Dong *et al.* (2021) supone el trabajo más parecido al que se presenta en este estudio. En su trabajo, Dong *et al.* (2021) emplean metodologías de aprendizaje automático para determinar la predictibilidad de la rentabilidad de mercado usando las rentabilidades pasadas de las carteras que explican la rentabilidad de los activos en la sección cruzada (factores). En el caso de nuestro trabajo, también realizamos una tarea de predicción, en este caso para la rentabilidad de una anomalía en concreto, *momentum*, utilizando exclusivamente información pasada sobre esa misma anomalía.

⁴ Otros trabajos que explotan *machine learning* para predecir la rentabilidad en la sección cruzada con múltiples predictores son Chincó, Clark-Joseph y Ye (2019), Freyberger, Neuhierl y Weber (2020), Avramov, Cheng y Metzker (2021), Cong *et al.* (2021), Liu, Zhou y Zhu (2021), Gu *et al.* (2021).

⁵ Trabajos clásicos en este sentido son, por ejemplo, Nelson (1976); Campbell (1987); Fama y French (1988, 1989); Pástor y Stambaugh (2003, 2009).

Las arquitecturas *LSTM* no se han explotado por ahora con frecuencia en la literatura académica. Como excepción, Chen *et al.* (2021), utilizan una arquitectura *LSTM* para extraer información de distintas variables macroeconómicas y para estimar el factor estocástico de descuento. Nuestra aplicación se basa en la predicción de la rentabilidad de *momentum* utilizando información pasada sobre la rentabilidad de sus componentes sobre distintos horizontes. De este modo, nuestro trabajo conecta con la literatura sobre modelos autorregresivos heterogéneos (Hizmeri *et al.*, 2022; Corsi, 2009; Bollerslev *et al.*, 2016). Nuestro modelo tiene en cuenta la relevancia de distintos horizontes predictivos, pero de una manera no lineal y flexible.

El resto de este trabajo se organiza como sigue. En la sección 2 describimos la metodología de investigación. En particular, describimos detalladamente los aspectos más relevantes de las redes neuronales recurrentes y su versión *LSTM*. En la sección 3 presentamos los resultados de predicción para el factor *momentum*. La sección 4 presenta las conclusiones.

2. METODOLOGÍA

2.1. Datos

En este estudio analizamos la serie temporal del factor *momentum* generado por las acciones de empresas cotizadas en Estados Unidos (NYSE, Nasdaq y AMEX). La fuente de datos es la página web del profesor Kenneth French. Para construir ese factor, en primer lugar, cada día se ordenan las acciones de mayor a menor rentabilidad en los doce meses anteriores, excluyendo el mes más reciente⁶. En el modelo de predicción utilizamos la información sobre la series temporales de rentabilidad diaria generadas por el 10 % de acciones con mayor rentabilidad⁷, r_t^{d1} , y por el 10 % de acciones con menor rentabilidad, r_t^{d10} .

Por su parte, la serie de rentabilidad diaria del factor *momentum*, r_t^{mom} , proviene de la diferencia en rentabilidades diarias entre el primer y el tercer tercil de la distribución de rentabilidad en los doce meses anteriores. El retorno de cada tercil se calcula utilizando la media de la rentabilidad entre empresas con capitalización bursátil mayor a la mediana y empresas con capitalización bursátil inferior a la mediana (datos obtenidos de la página web del profesor Kenneth French).

Para estimar el modelo de predicción transformaremos las rentabilidades diarias para construir rentabilidades sobre distintos horizontes. De manera formal, definimos la rentabilidad acumulada entre el periodo t y $t + s$ por la cartera p como:

⁶ La exclusión del mes más reciente se debe a la existencia de reversión en el corto plazo debido a factores de microestructura del mercado que pueden contaminar la selección en base a rentabilidades pasadas (Jegadeesh, 1990; Lehman, 1990; Jegadeesh y Titman, 1993).

⁷ La composición de $d1$ y $d10$ se actualiza de manera diaria, ver detalles en la página web del profesor Kenneth French.

$$r_{t,t+s}^p = \prod_{i=0}^s (1 + r_{t+i}^p) - 1$$

2.2. Redes neuronales recurrentes

Los modelos de predicción basados en redes neuronales representan uno de los núcleos fundamentales de los métodos de aprendizaje automático o *machine learning*. En diversos campos, desde la genética, hasta el reconocimiento del lenguaje, las redes neuronales han demostrado ser una herramienta versátil, eficiente y escalable para realizar ejercicios de predicción. Pese a que el concepto de “red neuronal artificial” fuera desarrollado en los años 60, las redes neuronales se han popularizado en las últimas dos décadas⁸. Esto se debe a: 1) la existencia y acumulación de una cantidad ingente de bases de datos masivas en las que las redes neuronales suelen rendir de manera notable respecto a otros métodos de *machine learning* y 2) el desarrollo de las tecnologías de computación que ha permitido manejar cantidades ingentes de datos e implementar algoritmos de optimización con miles (o millones) de parámetros.

Dentro de las redes neuronales, existe un método especializado en el procesamiento de secuencias de datos, ya sean series temporales, audio, notas musicales o texto, para desarrollar modelos predictivos. A este tipo de arquitectura se le denomina red neuronal recurrente (RNN). Las RNN son modelos de aprendizaje profundo que intentan capturar las dinámicas de secuencias a través de conexiones recurrentes. Las RNN consisten en una versión especial de red neuronal que se aplica a cada elemento de la secuencia, manteniendo siempre los mismos parámetros, y que aprende de la información pasada de la serie.

En nuestra aplicación, el objetivo consiste en predecir la rentabilidad del factor *momentum* a 25 días, $r_{t,t+25}^{mom}$ basándonos en información pasada sobre la rentabilidad de las carteras r_t^{d1} y r_t^{d10} en distintos horizontes. Utilizamos estos *inputs* para el modelo debido a que la diferencia entre r_t^{d1} y r_t^{d10} tiene capacidad predictiva sobre la rentabilidad del factor *momentum* (Huang, 2021). Asumamos que en el modelo de predicción incluimos dos horizontes: la rentabilidad en el día actual y la rentabilidad en los 60 días anteriores. Por tanto, en el momento s , el vector de *inputs* que para predecir $r_{t,t+25}^{mom}$ viene dado por:

$$x_s = \left\{ \left(r_s^{d1}, r_{s-60,s}^{d1} \right), \left(r_s^{d10}, r_{s-60,s}^{d10} \right) \right\}$$

donde cada *input* tiene una dimensión 1×4 . La estructura más simple de una red neuronal recurrente aparece en la figura 1. Para generar una predicción $\hat{r}_{t,t+25}^{mom}$, el modelo se nutre de información sobre una secuencia de inputs $\{x_{t-j}\}_{j=1}^K$, donde el parámetro K indica el número

⁸ El nombre de red neuronal se originó bajo la hipótesis de que las neuronas animales funcionan de manera parecida a este tipo de arquitectura de computación. No obstante, la investigación en biología muestra que esta representación es una mera aproximación metafórica del funcionamiento real de las neuronas animales.

de retardos que utilizamos para predecir el *output* en el momento t . Cada *input* x_s se introduce por separado en una “celda de activación” A cuyos parámetros son independientes del momento de tiempo. La celda de activación genera un “estado” h_s combinando el *input* x_s y la variable de “estado” generada en el elemento anterior de la serie:

$$h_s = \phi(x_s w_{xh} + h_{s-1} w_h + b_h)$$

donde $\phi(\cdot)$ es una función no lineal, “función de activación”, y se asume que $h_{\{t-K-1\}} = 0$. w_x , w_h y b_h son parámetros, o “pesos”, a entrenar. En particular, w_x es un vector de pesos con dimensión igual a la dimensión de x_s , mientras que los otros dos elementos, en este modelo más sencillo, son escalares.

El nombre de red neuronal recurrente proviene precisamente del hecho que la activación en cada elemento de la secuencia depende de la información específica de ese periodo e incluye información acumulada en el periodo anterior. El modelo incluye una especie de “memoria” en h_{t-j} , ya que depende de la información aprendida en elementos anteriores de la secuencia. En el modelo RNN más sencillo, la predicción $\hat{r}_{t,t+25}^{mom}$ para una secuencia de *inputs* vendrá dada por otra transformación no lineal del *input* final y el estado en h_{t-1} :

$$\hat{r}_{t,t+25}^{mom} = f(x_t w_{xy} + h_{t-1} w_{hy} + b_y)$$

donde $f(\cdot)$ es una función lineal o no lineal, mientras que w_{xy} , w_{hy} y b_y son parámetros a estimar. Este proceso de propagación en el tiempo finalmente genera un valor de la función de pérdida que compara el rendimiento real con el generado por el modelo⁹. Por ejemplo, si la función de pérdida viene dada por el error cuadrático medio, tendríamos que dentro de un subconjunto de observaciones \mathcal{T} (*mini-batch*):

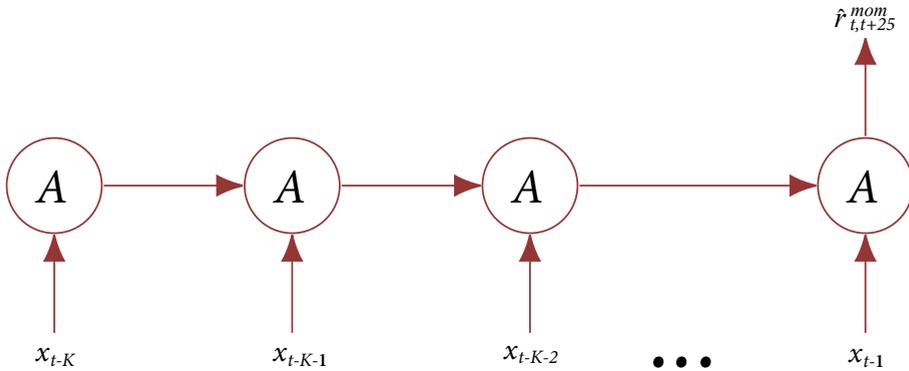
$$\mathcal{L}_{\mathcal{T}} = \frac{1}{|\mathcal{T}|} \sum_{s \in \mathcal{T}} (r_{s,s+25}^{mom} - \hat{r}_{s,s+25}^{mom})^2$$

donde $|\mathcal{T}|$ indica la cardinalidad del subconjunto.

Como analogía, podemos entender una RNN, y la arquitectura *LSTM* que describimos más adelante, como una versión especial de un modelo autorregresivo con heterogeneidad, donde la realización de la serie temporal en el futuro depende de la realización pasada de la serie vista desde diversos horizontes temporales. La capacidad adicional de predicción surge de la no-linealidad de las activaciones entre los distintos elementos de la secuencia.

⁹ Las arquitecturas RNN también permiten una diversidad de diseños de *inputs* y *outputs* que obviamos en la descripción ya que no los aplicamos en nuestro ejercicio de predicción. Las arquitecturas RNN pueden ser, entre otras, secuencia-a-secuencia, donde queremos predecir el *output* en todos los elementos, o vector-a-secuencia, donde utilizamos un único *input* para predecir una secuencia. Ver, por ejemplo, el capítulo 14 de Geron (2019) para una descripción más pormenorizada.

Figura 1.

Estructura de una red neuronal recurrente unicapa

El esquema anterior puede generalizarse incrementando el número de “neuronas” por celda. En tal caso nos encontraríamos con un vector de estados h_s en cada momento del tiempo, en vez de un escalar, e incrementaríamos la dimensión de los pesos a entrenar con el modelo. Lo anterior también puede combinarse con una estructura jerárquica, una “red profunda”, con distintas capas donde el estado de cada capa depende no sólo del *input* en el momento actual, x_s , y de los estados anteriores h_{s-1} , sino también de los estados obtenidos en las capas “inferiores” en el mismo elemento s . Si denominamos como $h_s^{(l)}$ el estado de la secuencia en el elemento s en la capa l la recurrencia de la red neuronal se puede expresar como:

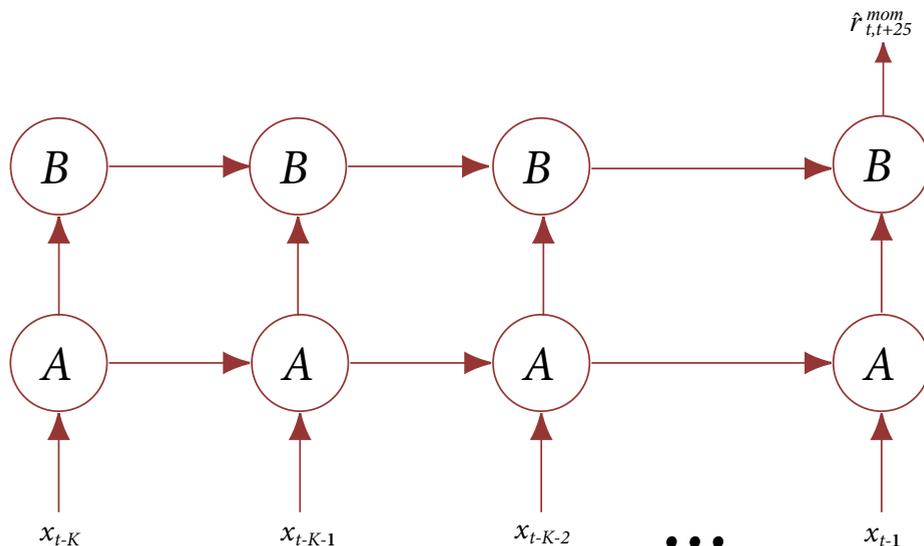
$$h_s^{(l)} = \phi \left(h_s^{(l-1)} w_{h0}^{(l)} + h_{s-1}^{(l)} w_{h1}^{(l)} + b_h^{(l)} \right)$$

con la normalización $x_s = h_s^0$. La figura 2 ilustra este tipo de arquitectura con dos capas. Como en la arquitectura básica anterior, la celda A se nutre de los *inputs* x_s y de los estados de la celda A en el elemento anterior de la secuencia. Por su parte, la celda B se nutre de los estados generados por la celda A y por los estados de la celda B en el elemento anterior de la secuencia.

El entrenamiento de las RNN usa la misma lógica de propagación inversa que se usa en las redes neuronales artificiales. No obstante, en el caso de las RNN, en cada elemento de la secuencia se mantienen los mismos pesos de las diferentes capas. La dinámica de entrenamiento de una RNN puede resumirse en tres pasos:

- Dados unos pesos, evaluar el error de predicción de la red en el subconjunto \mathcal{T} mediante la evolución secuencial, en orden cronológico, de los estados e *inputs*.
- Calcular los gradientes de la función de pérdida con respecto a cada uno de los pesos a entrenar sin tener en cuenta su repetición en cada elemento, es decir, como si la red tuviera pesos distintos en cada elemento.

Figura 2.

Estructura de una red neuronal recurrente con 2 capas

- Agregar los gradientes calculados en el paso anterior para cada uno de los pesos que se comparten en cada elemento de la secuencia. Actualizar los pesos usando el criterio de descenso de gradiente y volver al paso inicial hasta cumplir el criterio de convergencia.

Las arquitecturas anteriores tienen una estructura común en la que el estado h_s solamente captura información de los elementos anteriores en la secuencia. Otros modelos de redes recurrentes permiten que el estado también incorpore información de los elementos posteriores. Por ejemplo, en una tarea de reconocimiento de escritura puede ser necesario y más efectivo utilizar información posterior para entender mejor el contexto y reducir ambigüedades. Este principio también es aplicable a las series temporales en finanzas donde queremos extraer las señales más informativas para poder predecir la evolución futura de los precios de activos financieros¹⁰.

¹⁰ El funcionamiento de las redes RNN es análogo a los modelos de extracción de señales en series temporales con procesos de Markov ocultos. El capítulo 22 de Hamilton (1994) presenta una introducción a estos métodos. La estimación de estos modelos con procesos ocultos conlleva la estimación de las probabilidades de los estados no observables. Para ello, es útil explotar información sobre el pasado e información sobre el futuro de la serie. Esto es, conocer el estado oculto en el futuro es información útil para estimar el estado oculto en el momento actual, del mismo modo que es útil conocer el estado oculto en el pasado. La diferencia entre estos métodos es que las redes RNN intentan recoger los factores no observables que determinan la serie temporal teniendo en cuenta interacciones no lineales y sin realizar hipótesis sobre la distribución de las variables aleatorias.

Las redes neuronales recurrentes que permiten el entrenamiento hacia delante y hacia atrás en el tiempo se denominan redes bidireccionales. La **figura 3** ilustra el funcionamiento de este tipo de red. Las redes bidireccionales incorporan celdas como la celda *B* en el gráfico, que genera un estado nuevo utilizando información del futuro. De manera formal, si g_s representa el estado generado en dirección cronológicamente inversa, cada nuevo estado se nutre del *input* en el momento s y del estado g en el momento posterior:

$$g_s = \phi(x_s w_{xg} + g_{s+1} w_{gg} + b_g)$$

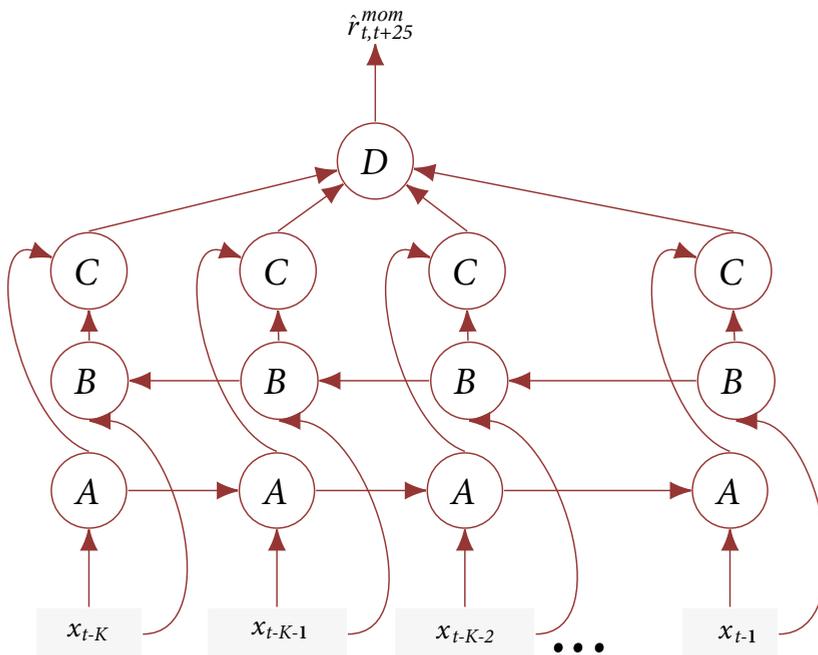
Donde asumimos que $g_{-t} = 0$. Por su parte, la celda *C* permite combinar el aprendizaje generado de manera independiente por las celdas *A* y *B* siguiendo distintas direcciones. Para generar una predicción final, los estados $\{(h_s, g_s)\}_{s=0}^t$ pueden combinarse en una capa adicional, *D*, al estilo de una red neuronal artificial tradicional (perceptrón multicapa o MLP) para generar una predicción final del *output*, $\hat{r}_{t,t+25}^{mom}$:

$$\hat{r}_{t,t+25}^{mom} = f(h w_{hy} + g w_{gy} + b_y)$$

donde h y g son vectores de dimensión $1 \times (h \times K)$ cada uno que resultan de la concatenación de los estados.

Figura 3.

Estructura de una red neuronal bidireccional



La dinámica de entrenamiento de una RNN bidireccional consiste en los siguientes pasos:

1. Dados unos pesos, evaluar los estados h_s y g_s de modo separado en el subconjunto \mathcal{T} .
2. Evaluar el error de predicción de la red dados los estados h_s y g_s junto a los pesos de la capa final de predicción.
3. Calcular los gradientes de la función de pérdida con respecto a los parámetros de la capa final de predicción.
4. Calcular los gradientes de la función de pérdida con respecto a los parámetros de las capas de propagación temporal.
5. Agregar los gradientes calculados en el paso anterior para todos y cada uno de los pesos que se comparten en cada elemento de la secuencia. Actualizar todos los pesos usando el criterio de descenso de gradiente y volver al paso inicial hasta cumplir el criterio de convergencia.

En principio, el diseño de las arquitecturas RNN puede resultar muy adecuado y eficiente para manejar información en forma de secuencias. No obstante, las RNN tienen dos graves problemas en la práctica. En primer lugar, el entrenamiento de la red requiere una propagación inversa, hacia atrás en el tiempo, que debe realizarse a través de los K niveles de cada secuencia que se introduzca en el modelo. Esta propagación hacia atrás en el tiempo genera una cadena de productos de matrices que fácilmente genera inestabilidades numéricas cuando se ejecuta el descenso de gradiente (explosión o desaparición del gradiente). Como consecuencia de lo anterior, los modelos RNN conllevan un entrenamiento con una gran demanda en términos computacionales.

En segundo lugar, los estados generados por los modelos RNN no permiten tener en cuenta que algunos elementos alejados de la secuencia puedan tener una relevancia considerable en el *output* actual. La estructura de las RNN hace que los elementos alejados pierdan relevancia de manera exponencial. También puede haber información reciente que no aporte poder predictivo y que sea mejor “olvidar”. Incluso podemos esperar algún tipo de cambio estructural en la serie que pueda afectar a la capacidad predictiva del modelo, de modo que sea más adecuado “resetear” el modelo. Las arquitecturas que utilizamos para desarrollar nuestro modelo predictivo de *momentum* nos permiten, o al menos aspiramos a ello, recoger este tipo de comportamientos en las series temporales, permitiendo a su vez menores costes computacionales.

2.3. Redes neuronales recurrentes con *LSTM*

El diseño de las arquitecturas *LSTM* afronta el desafío de preservar la información de largo plazo relevante y de ignorar la información de corto plazo irrelevante (Hochreiter y Schmidhuber, 1997). El modelo *LSTM* consiste en el diseño de una celda que absorbe el *input*

actual y el estado anterior y selecciona la información a absorber. Para ello, en el interior de la celda *LSTM* se realizan ciertas operaciones a través de las denominadas “puertas lógicas” (*gates*). El entrenamiento de los parámetros incluidos en esas puertas lógicas permite a la arquitectura filtrar qué información nueva aprender en el estado y qué información ignorar.

En cada elemento de la secuencia la celda *LSTM* se nutre del input x_t , con dimensión $1 \times d$, y del estado en el elemento anterior h_{t-1} , con dimensión $1 \times h$. Esta información es procesada de manera independiente por tres distintas puertas lógicas: *Input*, *Forget* y *Output*. Las tres puertas lógicas tienen valores en $(0, 1)$ al tener asociados una función de activación sigmoidal, $\sigma(z) = (1 + \exp(-z))^{-1}$. Formalmente, las tres puertas lógicas se calculan como:

$$i_t = \sigma(x_t W_{xi} + h_{t-1} W_{hi} + b_i),$$

$$f_t = \sigma(x_t W_{fi} + h_{t-1} W_{fi} + b_f),$$

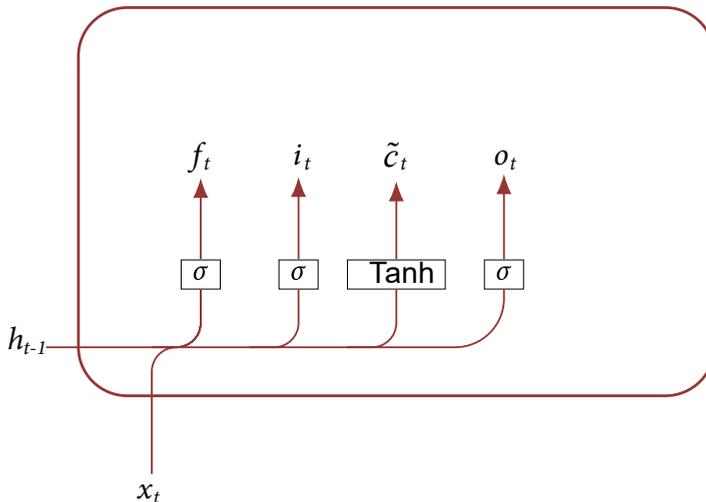
$$o_t = \sigma(x_t W_{oi} + h_{t-1} W_{ho} + b_o)$$

donde W_{xi} , W_{fi} , $W_{oi} \in \mathbb{R}^{d \times h}$ y W_{hb} , W_{hb} , $W_{hi} \in \mathbb{R}^{h \times h}$ y b_i , b_f , $b_o \in \mathbb{R}^{1 \times h}$ son parámetros a entrenar. Además, en este paso inicial se determina una “memoria candidata”, \tilde{c}_t , que podrá incorporarse a la memoria a largo plazo según el resultado de la puerta lógica *Input*. \tilde{c}_t , con dimensión $1 \times h$, se calcula a partir de x_t y h_{t-1} y viene dada por una función de activación tangente hiperbólica, $\tanh(z) = (\exp(z) - \exp(-z))/(\exp(z) + \exp(-z))$, que genera valores restringidos en el rango $(-1, 1)$:

$$\tilde{c}_t = \tanh(x_t W_{xc} + h_{t-1} W_{hc} + b_c)$$

Figura 4.

Estructura de puertas lógicas y memoria candidata



donde $W_{xc} \in \mathbb{R}^{d \times h}$ y $W_{hc} \in \mathbb{R}^{h \times h}$ y $b_c \in \mathbb{R}^{1 \times h}$ son pesos a entrenar. El proceso de cálculo de las tres puertas lógicas y la memoria candidata está ilustrado en la **figura 4**.

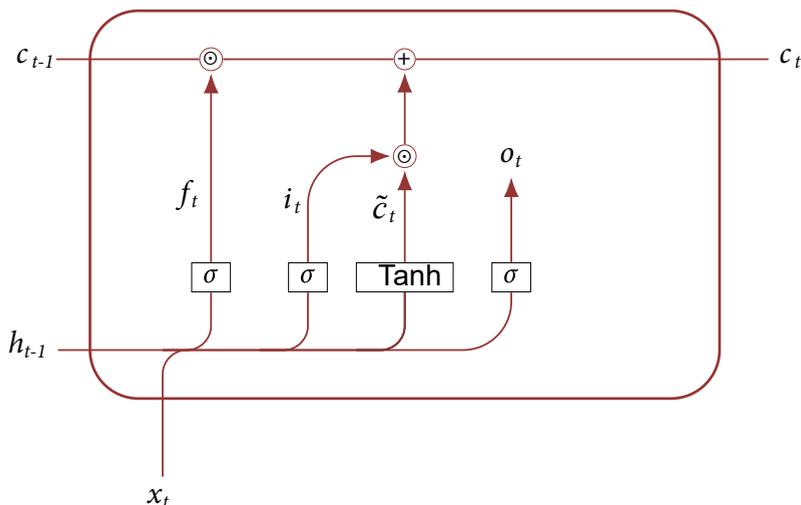
La celda *LSTM* tiene dos puertas lógicas dedicadas a determinar el grado de incorporación y “olvido” de la memoria a largo plazo. La puerta lógica *Input* determina el grado de incorporación de información creada en \tilde{c}_t . La puerta lógica *Forget* determina el grado de memoria heredada del elemento anterior, $c_{t-1} \in \mathbb{R}^h$, que se mantiene. La memoria a largo plazo se actualiza mediante la siguiente ecuación:

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t$$

donde el operador \odot representa la multiplicación de matrices elemento por elemento. f_t e i_t se encuentran en el intervalo $(0, 1)$ y determinan, respectivamente, el grado eliminación de memoria pasada y el grado de incorporación de información presente a la memoria actual. El diseño de las funciones de activación permite aliviar el problema de explosión/desaparición del gradiente, mientras que el mantenimiento de la memoria c_t permite capturar la relevancia de las dependencias de largo plazo entre los elementos de la serie.

Figura 5.

Estructura de celda LSTM



El último paso consiste en definir el estado h_t originado en la celda *LSTM*:

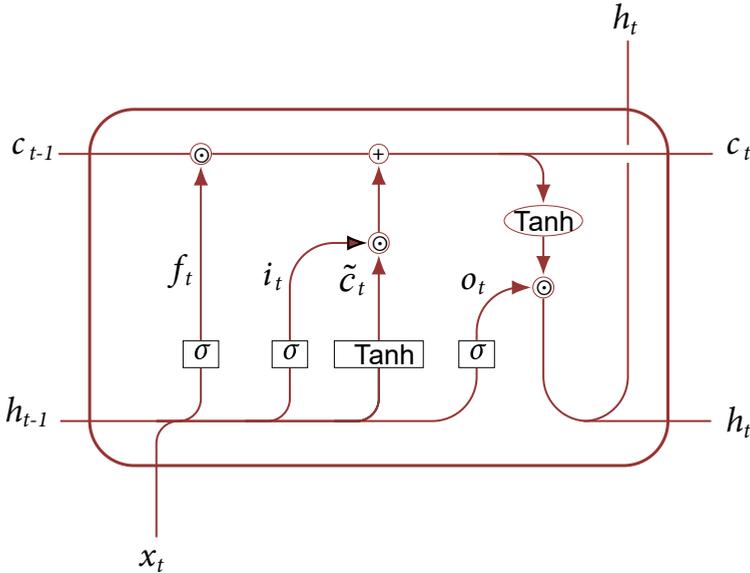
$$h_t = o_t \odot \tanh(c_t)$$

Si la puerta lógica *Open*, o_t , se aproxima a 1 el modelo permite acceder a toda la memoria a largo plazo hacia la predicción del estado. En caso contrario, cuando o_t se aproxima a 0,

se retiene la información dentro de la celda y no se pasa al siguiente elemento. La estructura final de una celda *LSTM* está ilustrada en la figura 5. El estado h_t también puede utilizarse como *input* para la predicción o como *input* para una capa superior de otra celda *LSTM*.

Figura 6.

Estructura de celda *LSTM* y *output* de estado



La arquitectura *LSTM*, pese a su aparente complejidad, permite un entrenamiento “más fluido” con respecto a las RNN básicas. Esto se debe a que en una RNN básica la cantidad de información absorbida en cada periodo de tiempo a través de h_{t-1} es independiente del elemento de la secuencia en el que nos encontremos. Mientras tanto, en una *LSTM* las puertas lógicas f_t y i_t permiten que la información absorbida sea específica en cada elemento de la secuencia. Es más, al ignorarse cierta información, el modelo puede filtrar información de elementos lejanos que sea relevante para la predicción.

2.4. Diseño de la arquitectura de aprendizaje

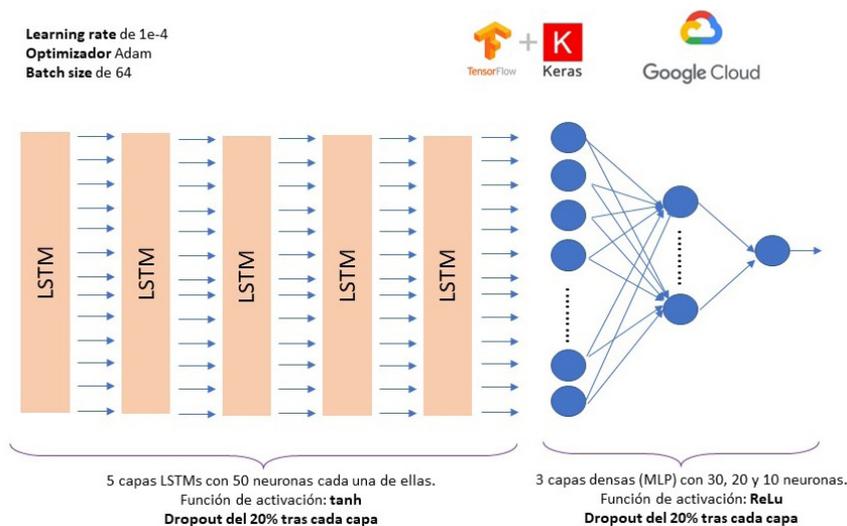
Para la estimación del modelo se ha recurrido a una arquitectura compuesta por 5 capas de redes *LSTM* (bidireccionales) con 50 neuronas cada una de ellas que se completan, tras cada una de ellas, con un capa de dilución (*dropout*) del 20 %. El *dropout* es un técnica de regularización que pretende mitigar posibles problemas de sobreajuste en la arquitectura. Por último, tras la salida de la última capa *LSTM*, la arquitectura incluye tres capas perceptrón multicapa (“MLP” o capas densas) de 30, 20 y 10 neuronas, respectivamente. La función de

activación utilizada es la tangente hiperbólica (“tanh”) para las capas LSTM y la función rectificadora (“ReLU”) para las capas MLP. La figura 7 ilustra la arquitectura y los principales hiperparámetros utilizados.

El entrenamiento y desarrollos de la arquitectura ha sido realizado con Tensorflow-Keras y la arquitectura ha sido entrenada en Google Cloud mediante el uso de GPU (“Graphics Processing Unit”) por sus ventajas computacionales.

Figura 7

Estructura de la arquitectura y principales hiperparámetros



Como describimos anteriormente, para entrenar y evaluar el modelo utilizamos datos diarios del factor *momentum* desde el año 1926 hasta la actualidad, año 2022. Para obtener las predicciones $\hat{r}_{t,t+25}^{mom}$ utilizamos una secuencia de *inputs* $\{x_{t-j}\}_{j=1}^K$ con $K = 60$. Del total de observaciones, se han utilizado para el conjunto de entrenamiento $\mathcal{T}_1 = 12.410$ observaciones, para el conjunto de validación¹¹ $\mathcal{T}_2 = 3.013$ observaciones, y se han reservado $\mathcal{T}_3 = 9.284$ observaciones para el conjunto de test. De esta forma, considerando la secuencia temporal, el periodo de entrenamiento y validación iría desde el año 1926 hasta el año 1983, reservando desde 1984 hasta el año 2022 para el test.

2.5. Medición de la capacidad predictiva y valor económico

Para medir la capacidad predictiva del modelo desde un punto de vista estadístico, utilizamos como referencia un modelo de predicción que utiliza la media histórica de la rentabi-

¹¹ El conjunto de validación se ha utilizado exclusivamente para la detención temprana, *early stopping*, del entrenamiento.

lidad $r_{t,t+25}^{mom}$ en el conjunto de las muestras de entrenamiento y validación, \bar{r}^{mom} . Los errores de predicción del modelo de referencia y del modelo LSTM vendrán dados por:

$$\hat{e}_{M,t} = r_{t,t+25}^{mom} - \bar{r}^{mom}$$

$$\hat{e}_{LS,t} = r_{t,t+25}^{mom} - \hat{r}_{t,t+25}^{mom}$$

Por tanto, el error cuadrático medio de las predicciones de cada modelo se puede expresar como:

$$\widehat{ECM}_j = \frac{1}{|T_3|} \sum_{t \in T_3} \hat{e}_{j,t}^2 \text{ for } j \in \{M, LS\}$$

donde $|T_3|$ indica el número de observaciones en la muestra test. Una vez calculados los errores de predicción de ambos modelos podemos construir el estadístico R_{OOS}^2 de Campbell y Thompson (2008):

$$R_{OOS}^2 = 1 - \frac{\widehat{ECM}_{LS}}{\widehat{ECM}_M}$$

El componente predecible de las rentabilidades es muy escaso, pero Campbell y Thompson (2008) sugieren que un R_{OOS}^2 superior a un 0,5 % implican ganancias de utilidad económicamente relevantes. Además, para comprobar la significatividad estadística de la estimación del R_{OOS}^2 , realizamos el contraste de hipótesis de Clark y West (2007) que puede implementarse a través del siguiente modelo de regresión:

$$\hat{e}_{M,t}^2 - \hat{e}_{LS,t}^2 + (\bar{r}^{mom} - \hat{r}_{t,t+25}^{mom})^2 = \mu + \varepsilon_t$$

El estadístico t asociado al estimador MCO del coeficiente μ en la regresión anterior sirve para contrastar las siguientes hipótesis:

$$H_0 : R_{OOS}^2 \leq 0; H_a : R_{OOS}^2 > 0$$

Es decir, rechazamos la hipótesis de que la predicción LSTM es igual o peor que la media histórica cuando el p-valor del contraste unilateral de significatividad de la estimación de μ es suficientemente pequeño.

Además de comparar la capacidad predictiva de los modelos en términos estadísticos, también comparamos el valor económico generado para un inversor representativo. Consideramos un inversor con preferencias media-varianza que distribuye su riqueza entre bonos sin riesgo y una estrategia *momentum*. Dependiendo del método de predicción usado por el inversor, los pesos de la estrategia *momentum* en la cartera vendrán dados por:

$$w_{M,t,t+25} = \frac{1}{\gamma} \left(\frac{\bar{r}^{mom} - r_{t,t+25}^f}{\hat{\sigma}_t^2} \right)$$

$$w_{LS,t,t+25} = \frac{1}{\gamma} \left(\frac{\hat{r}_{t,t+25}^{mom} - r_{t,t+25}^f}{\hat{\sigma}_t^2} \right)$$

donde $r_{t,t+25}^f$ es la rentabilidad libre de riesgo a 25 días y γ captura la aversión al riesgo del inversor¹². Siguiendo los procedimientos de la literatura (Dong *et al.*, 2021), asumimos que γ toma un valor de 3 y que el inversor estima la volatilidad de la rentabilidad de *momentum* $\hat{\sigma}_t$ usando la varianza de las rentabilidades en los anteriores doce meses. La utilidad de cada estrategia viene dada por:

$$\bar{U}_j = \bar{r}_j - \frac{\gamma}{2} \hat{\sigma}_j^2 \text{ para } j \in \{M, LS\}$$

donde \bar{r}_j es la rentabilidad media de la estrategia j respecto a la rentabilidad libre de riesgo y $\hat{\sigma}_j$ es la desviación típica de la rentabilidad. Para determinar el valor económico creado con el modelo de predicción *LSTM* respecto a la media histórica, calculamos la diferencia de utilidades $\Delta = \bar{U}_{LS} - \bar{U}_M$.

Ya que utilizamos datos diarios para estimar el modelo de predicción a 25 días, para cada modelo y cada día obtenemos 25 carteras activas, de las cuales solamente una se rebalanea. Por tanto, calculamos por separado la utilidad generada por cada cartera entre sus fechas de rebalanceo a lo largo de la muestra de test y posteriormente calculamos la media entre las 25 carteras.

Un aspecto relevante para señalar es que la estrategia que utiliza la media histórica para determinar el peso de la cartera *momentum* puede parecer una opción inferior. Sin embargo, Welch y Goyal (2008) muestran que la media histórica es una opción competitiva en relación a los modelos lineales tradicionales para predecir la rentabilidad. Además, la estrategia de inversión de la cartera media-varianza está ajustada mediante una estimación de la volatilidad usando la volatilidad pasada. Este tipo de ajuste suele generar rentabilidades superiores a carteras que no están ajustadas por volatilidad (Moreira y Muir, 2017). Además, en el caso de *momentum*, ese ajuste es suficiente para reducir la exposición a los episodios de rentabilidad negativa extrema o *crashes* (Barroso y Santa Clara, 2015; Daniel y Moskowitz, 2016).

3. RESULTADOS

El cuadro 1 presenta los resultados de la predicción *out-of-sample* de cada uno de los modelos *LSTM* entrenados, donde la referencia en cada caso es la predicción de rentabilidad que utiliza la media histórica en las muestras de entrenamiento y validación. La columna 1 muestra que el estimador R_{OOS}^2 es superior al 0,5 % en todos los modelos, lo que implica ganancias de predicción relevantes, desde el punto de vista estadístico y económico, del uso del modelo no lineal respecto a una predicción solamente basada en la media histórica. El mayor poder predictivo está generado por el modelo que solamente utiliza información sobre las rentabilidades de las carteras *momentum* a un día y a 120 días, R_{OOS}^2 del 2,49 %. Cuando incluimos más información en el modelo añadiendo la rentabilidad a 60 días y a 240 días

¹² La información sobre la rentabilidad libre de riesgo también se ha extraído de la web de Kenneth French y se corresponde con la rentabilidad diaria de las letras del Tesoro de EE. UU. con vencimiento a un mes.

como elementos del vector x_s , el poder predictivo se reduce. Este resultado evidencia cierto exceso de ajuste (*overfitting*) en las muestras de entrenamiento y validación cuando incluimos más información en el modelo *LSTM*. En términos estadísticos, en tres de los cuatro modelos podemos rechazar la hipótesis nula de que el modelo *LSTM* sea igual o inferior en términos de errores de predicción comparados con la predicción basada en la media histórica.

En términos de valor económico para un inversor con preferencias media-varianza, la columna 2 muestra las ganancias de utilidad generadas por los modelos *LSTM*. En consonancia con los estadísticos R_{OOS}^2 de la columna 1, los modelos *LSTM* generan una ganancia de utilidad con respecto al modelo de predicción de referencia. De nuevo el modelo que genera una mayor ganancia de utilidad es el que combina información de las rentabilidades de las carteras *momentum* a un día y a 120 días.

Pese a lo anterior, un aspecto a destacar es que el *ranking* de estrategias basados en valor económico no sigue el mismo orden que en términos de poder predictivo. Paradójicamente, la peor estrategia en valor económico es la que utiliza un conjunto más amplio de información. Esto se debe a que el R_{OOS}^2 es una medida que captura puramente la capacidad predictiva, sin distinguir entre compensación por el riesgo (“beta”) y compensación por errores de valoración (“alpha”). Además el ECM de la estrategia puede estar muy influenciado por eventos extremos en los que el modelo predice extremadamente bien. El modelo que utiliza más información puede ser más preciso en media pero generar una variación excesiva en la rentabilidad, como de hecho mostraremos a continuación.

Cuadro 1.

Poder de predicción *out-of-sample* y valor económico

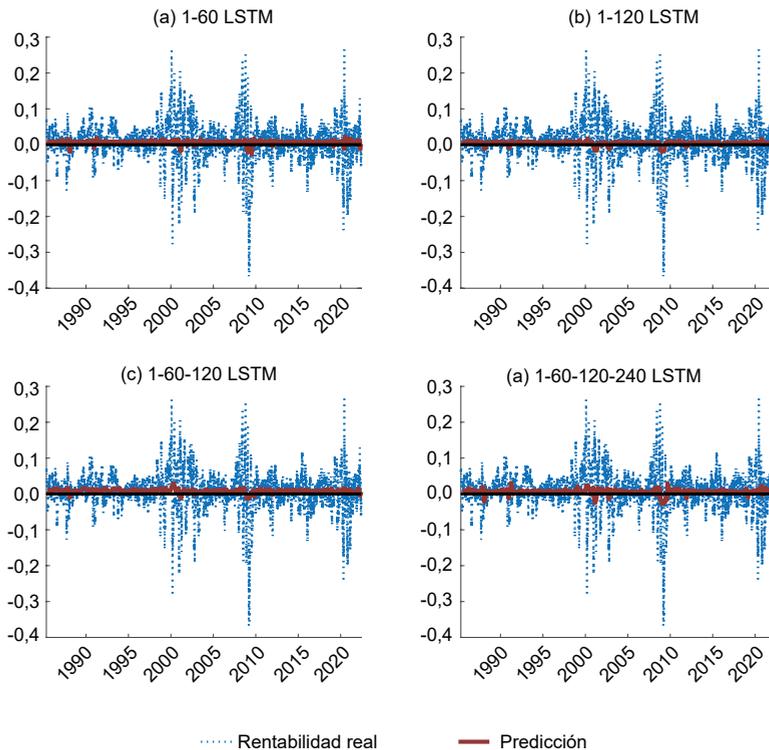
Modelo	(1) R_{OOS}^2 (%)	(2) Δ (%)
LSTM 1-60	0,536 (0,150)	0,990
LSTM 1-120	2,486* (0,071)	2,585
LSTM 1-60-120	1,896* (0,058)	1,787
LSTM 1-60-120-240	2,100* (0,099)	0,568

La figura 8 ilustra la capacidad predictiva del modelo como proporción de la variación global de la rentabilidad asociada al factor *momentum*. Los paneles representan, en líneas sólidas, las predicciones de rentabilidad realizadas por cada modelo *LSTM*. Las líneas discontinuas representan la rentabilidad real del factor *momentum*. Los modelos generan predicciones en general de rentabilidad positiva con poca variación en relación con la variación real de la rentabilidad. No obstante, los modelos tienden a predecir una rentabilidad negativa en la serie temporal en ciertos periodos señalados, que suelen estar marcados por episodios de gran volatilidad. Por tanto, los modelos *LSTM* consiguen poder predictivo por encima

de una simple media histórica al aprender la relación entre volatilidad de la rentabilidad de *momentum* y la realización de rentabilidades negativas.

Figura 8.

Rentabilidades modelo *LSTM* vs. factor *momentum*



La figura 9 muestra la rentabilidad acumulada por las distintas estrategias por encima de la rentabilidad libre de riesgo en el periodo *out-of-sample*, expresada en logaritmos. En todos los paneles, a modo de referencia y en una serie temporal con puntos, se muestra la rentabilidad acumulada de una estrategia “Buy&Hold” que invierte todos los fondos del inversor en la cartera *momentum*¹³. Esta estrategia genera una rentabilidad positiva a lo largo del periodo, pero muy influenciada por el *crash* sufrido por la estrategia en 2009.

A su vez, la serie temporal con líneas discontinuas muestra la rentabilidad acumulada por la estrategia que determina el peso sobre la cartera *momentum* utilizando la media histórica, denominada estrategia “Base”. Como muestra la figura, esta estrategia bate la rentabilidad de la estrategia “Buy&Hold”. Esta mayor rentabilidad se explica fundamentalmente por

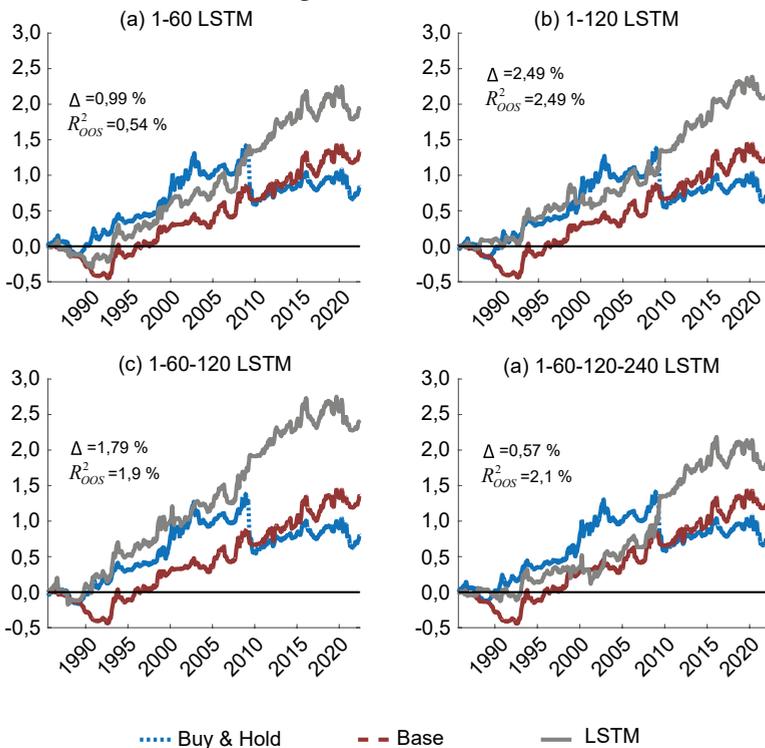
¹³ Ya que en cada momento hay 25 carteras activas, cada punto en el gráfico muestra una media con ventana móvil de 25 observaciones pasadas.

su mínima exposición al *crash* de 2009 y corrobora la efectividad de la ponderación por la volatilidad pasada (Barroso y Santa Clara, 2015; Daniel y Moskowitz, 2016).

Por su parte, cada uno de los paneles de la **figura 9** representa en una línea continua la rentabilidad acumulada por las cuatro estrategias basadas en los modelos *LSTM*. Los cuatro modelos de predicción son capaces de batir a las otras dos estrategias de referencia en términos de rentabilidad acumulada. La mayor rentabilidad acumulada está generada por la estrategia que utiliza las rentabilidades de las carteras *momentum* a un día, a 60 días y a 120 días. Las ganancias de las estrategias *LSTM* se basan en una predicción notable del *crash* de 2009 por parte de todos los modelos.

Figura 9.

Rentabilidad acumulada estrategias *LSTM*



Para completar el análisis de los resultados, el **cuadro 2** muestra algunos estadísticos descriptivos adicionales de las estrategias. Los resultados muestran cómo las estrategias basadas en *LSTM* generan una rentabilidad media a 25 días considerablemente mayor que las estrategias “Base” y “Buy&Hold”. La volatilidad de las estrategias *LSTM* son relativamente superiores a la estrategia “Base”, pero sus ratios de Sharpe muestran que la compensación en rentabilidad por unidad de riesgo es sustancialmente mayor.

La comparación entre los distintos modelos *LSTM* ofrece una visión análoga a los resultados presentados anteriormente. La estrategia que solamente utiliza información sobre las rentabilidades de las carteras *momentum* a un día y a 120 días supera en términos de relación rentabilidad-riesgo a las otras estrategias, pese a no conseguir la rentabilidad media mayor. Además, el signo de la asimetría de esas rentabilidades se invierte con respecto al resto de estrategias (excepto para el modelo que utiliza el mayor nivel de información) sugiriendo una menor exposición a rentabilidades extremas negativas, como también indica el valor de curtosis (7,4 respecto a 9,3 de la estrategia “Buy&Hold”).

Cuadro 2.

Estadísticos de las distintas estrategias

Modelo	Rentabilidad media (%)	Volatilidad (%)	Ratio de Sharpe	Asimetría	Curtosis
Buy&Hold	0,649	5,068	0.24	-0.996	9.298
Base	0,744	4,526	0.344	-0.038	7.002
LSTM 1-60	0,919	5,169	0.419	-0.085	6.696
LSTM 1-120	0,984	4,701	0.508	0.267	7.492
LSTM 1-60-120	1,096	5,832	0.476	-0.244	6.427
LSTM 1-60-120-240	0,92	5,392	0.404	0.219	8.298

4. CONCLUSIONES

En este trabajo hemos analizado la capacidad de las arquitecturas de redes neuronales *Long Short-Term Memory (LSTM)* para predecir la serie temporal del factor *momentum*. La arquitectura *LSTM* supone una de las herramientas más potentes en el campo de *machine learning* para realizar predicciones en datos con forma de secuencia, pero ha sido aplicado de manera muy limitada en el área académica de las finanzas. Por su parte, la anomalía *momentum* supone uno de los fenómenos más analizados en el ámbito de las finanzas por su prevalencia en el tiempo y su marcado carácter de “anomalía” que desafía a las teorías de eficiencia.

Los resultados sugieren que los modelos *LSTM* pueden predecir de manera notable la serie temporal del factor *momentum* y anticipar episodios de rentabilidad extrema. Las estrategias de inversión que resultan de los modelos *LSTM* dominan considerablemente a una estrategia basada en la media histórica, incluso ponderando las estrategias por la volatilidad pasada del factor *momentum*. Las ganancias en la predicción se traducen en medidas de R^2 fuera de la muestra (*out-of-sample*) y ganancias económicas de más del 2 %.

Diversas líneas de trabajo pueden continuar el análisis realizado en este estudio. En primer lugar, las arquitecturas entrenadas son relativamente sencillas y están destinadas a ilustrar el poder predictivo de este tipo de modelos. Determinar la capacidad predictiva de estos modelos necesita un análisis más exhaustivo de las arquitecturas, los hiperparámetros y

la información usada en el modelo. Segundo, resulta de interés aplicar las arquitecturas *LSTM* para comprobar su poder predictivo respecto a otros factores y anomalías analizados en la literatura. Finalmente, queda la tarea pendiente de refinar la interpretabilidad de la información absorbida por las redes *LSTM*. Para ello, someter el entrenamiento de la arquitectura a la intuición económica nos puede servir para detectar los patrones relevantes de predictibilidad de las series temporales en finanzas.

Referencias

- ALTI, A. y TITMAN, S. (2019). A dynamic model of characteristic-based return predictability. *The Journal of Finance*, 74(6), 3187-3216.
- AVRAMOV, D., CHORDIA, T., JOSTOVA, G. y PHILIPPOV, A. (2013). Anomalies and financial distress, *Journal of Financial Economics*, 108, 1391-159.
- BACHELIER, L. (1900). Théorie de la spéculation. *Annales Scientifiques de l'École Normale Supérieure*, vol. 3, no. 17, pp. 218-6.
- BARROSO, P. y SANTA-CLARA, P. (2015). Momentum has its moments. *Journal of Financial Economics*, 116(1), pp. 111-120.
- BLANCO, I., DE JESUS, M. y REMESAL, A. (2023). Overlapping Momentum Portfolios. *Journal of Empirical Finance*, 72, pp. 1-22.
- BOLLERSLEV, T., PATTON, A. J. y QUAEDVLIEG, R. (2016). Exploiting the errors: A simple approach for improved volatility forecasting. *Journal of Econometrics*, 192(1), pp. 1-18.
- CAMPBELL, J. Y. (1987). Stock returns and the term structure. *Journal of Financial Economics*, 18, 373-399.
- CAMPBELL, J. Y. y SHILLER, R. J. (1988). The dividend-price ratio and expectations of future dividends and discount factors. *The Review of Financial Studies*, 1(3), pp. 195-228.
- CHEN, L., PELGER, M. y ZHU, J. (2023). Deep learning in asset pricing. *Management Science*.
- CHINCO, A., CLARK-JOSEPH, A. D. y YE, M. (2019). Sparse signals in the cross-section of returns. *Journal of Finance*, 74, 4494-92.
- CLARK, T. E. y WEST, K. D. (2007). Approximately normal tests for equal predictive accuracy in nested models. *Journal of Econometrics*, 138(1), 291-311.
- COCHRANE, J. H. (2007). The dog that did not bark: A defense of return predictability. *The Review of Financial Studies*, 21, 1533-75.
- CONG, L., KE TANG, J. y ZHANG, Y. (2021). Alphaportfolio: Direct construction through deep reinforcement learning and interpretable AI. *Working paper*. Cornell University, Tsinghua University y Beihang University.
- CORSI, F. (2009). A simple approximate long-memory model of realized volatility. *Journal of Financial Econometrics*, 7(2), pp. 174-196.
- DA, Z., GURUN, U. G. y WARACHKA, M. (2014). Frog in the pan: Continuous information and momentum. *Review of Financial Studies*, 27(7), 2171-2218.
- DANIEL, K., HIRSHLEIFER, D. y SUBRAHMANYAM, A. (1998). Investor psychology and security market under- and overreactions. *Journal of Finance*, 53(6), 1839-1885.
- DANIEL, K. y MOSKOWITZ, T. J. (2016). Momentum crashes. *Journal of Financial Economics*, 122(2), pp. 221-247.

- DONG, X., LI, Y., RAPACH, D. E. y ZHOU, G. (2022). Anomalies and the Expected Market Return. *The Journal of Finance*, 77, pp. 639-681.
- ENGELBERG, J., DAVID MCLEAN, R. y PONTIFF, J. (2018). Anomalies and news. *Journal of Finance*, 73, 19712001.
- FAMA, E. F., FISHER, L., JENSEN, M. C. y ROLL, R. (1969). The Adjustment of Stock Prices to New Information. *International Economic Review*, 10(1), p. 121.
- FAMA, E. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), 383417.
- FAMA, E. F. y FRENCH, K. R. (1988). Dividend yields and expected stock returns. *Journal of Financial Economics*, 21, p. 325.
- FAMA, E. F. y FRENCH, K. R. (1989). Business conditions and the expected returns on stocks and bonds. *Journal of Financial Economics*, 25, p. 2349.
- FAMA, E. F. y FRENCH, K. R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, 33, p. 356.
- FAMA, E. F. y FRENCH, K. R. (2015). A five-factor asset pricing model. *Journal of Financial Economics*, 116, p. 122.
- FAMA, E. F. y FRENCH, K. R. (2020). Comparing cross-section and time-series factor models. *Review of Financial Studies*, 33, 18911926.
- FREYBERGER, J., NEUHIERL, A. y WEBER, M. (2020). Dissecting characteristics nonparametrically. *Review of Financial Studies*, 33, 23262377.
- GERON, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras and TensorFlow: Concepts, tools, and techniques to build intelligent systems* (2nd ed.). O'Reilly.
- GRANGER, C. W. J. y MORGENSTERN, O. (1970). *Predictability of Stock Market Prices*. Heath Lexington Books.
- GU, S., KELLY, B. y XIU, D. (2020). Empirical asset pricing via machine learning. *Review of Financial Studies*, 33, 22232273.
- GU, S., KELLY, B. y XIU, D. (2021). Autoencoder asset pricing models. *Journal of Econometrics*, 222(1), pp. 429-450.
- HAMILTON, J. D. (1994). *Time Series Analysis*. Princeton University Press.
- HAN, Y., HE, A., RAPACH, D. E. y ZHOU, G. (2021). Expected stock returns and firm characteristics: E-LASSO, assessment, and implications. *Working paper*. University of North Carolina, Charlotte, University of South Carolina, Saint Louis University y Washington University in St. Louis.
- HARVEY, C. R., LIU, Y. y ZHU, H. (2016). And the cross-section of expected returns. *Review of Financial Studies*, 29, p. 568.
- HIRSHLEIFER, D. y LUO, G. Y. (2001). On the survival of overconfident traders in a competitive securities market. *Journal of Financial Markets*, 4(1), 7384.
- HIZMERI, R., IZZELDIN, M., NOLTE, I. y PAPPAS, V. (2022). A generalized heterogeneous auto-regressive model using market information. *Quantitative Finance*, pp. 1-22.
- HOCHREITER, S. y SCHMIDHUBER, J. (1997). Long short-term memory. *Neural computation*, 9(8), pp. 1735-1780.
- HONG, H. y STEIN, J. C. (1999). A unified theory of underreaction, momentum trading, and overreaction in asset markets. *Journal of Finance* 54(6), 21432184.
- HOU, K., XUE., C. y ZHANG, L. (2020). Replicating anomalies. *Review of Financial Studies*, 33, 20192133.
- HUANG, D., LI, J., WANG, L. y ZHOU, G. (2020). Time series momentum: Is it there? *Journal of Financial Economics*, 135(3), pp. 774-794.

- HUANG, S. (2022). The Momentum Gap and Return Predictability. *The Review of Financial Studies*, Volume 35, Issue 7, July 2022, 33033336.
- JEGADEESH, N. (1990). Evidence of predictable behavior of security returns. *The Journal of Finance*, 45(3), pp. 881-898.
- JEGADEESH, N. y TITMAN, S. (1993). Returns to buying winners and selling losers: Implications for stock market efficiency. *The Journal of Finance*, 48(1), pp. 65-91.
- KOZAK, SERHIY, S. N. y SANTOSH, S. (2020). Shrinking the cross-section. *Journal of Financial Economics*, 135, 271292.
- LEHMANN, B. N. (1990). Fads, martingales, and market efficiency. *The Quarterly Journal of Economics*, 105(1), pp. 1-28.
- LIU, Y., ZHOU, G. y ZHU, Y. (2021). Maximizing the Sharpe ratio: A genetic programming approach. *Working paper*. Tsinghua University and Washington University in St. Louis.
- MCLEAN, R. D. y PONTIFF, J. (2016). Does academic research destroy stock return predictability? *The Journal of Finance*, 71(1), pp. 5-32.
- MOREIRA, A. y MUIR, T. (2017). Volatility-managed portfolios. *The Journal of Finance*, 72(4), pp. 1611-1644.
- MOSKOWITZ, T. J., OOI, Y. H. y PEDERSEN, L. H. (2012). Time series momentum. *Journal of Financial Economic*, 104(2), pp. 228-250. Special Issue on Investor Sentiment.
- NELSON, C. R. (1976). Inflation and rates of return on common stocks. *The Journal of Finance*, 31, 471483.
- PÁSTOR, L. y STAMBAUGH, R. F. (2003). Liquidity risk and expected stock returns. *Journal of Political Economy*, 111, 642685.
- PÁSTOR, L. y STAMBAUGH, R. F. (2009). Predictive systems: Living with imperfect predictors. *The Journal of Finance*, 64, 15831628.
- RAPACH, D. E., STRAUSS, J. K. y ZHOU, G. (2013). International stock return predictability: What is the role of the United States? *Journal of Finance*, 68, 16331662.
- RAPACH, D. E. y ZHOU, G. (2020). Timeseries and crosssectional stock return forecasting: New machine learning methods. *Machine learning for asset management*. *New developments and financial applications*, 1-33.
- ROSS, S. A. (1976). The arbitrage theory of capital asset pricing. *Journal of Economic Theory*, 13(3), pp. 341-360.
- WELCH, I. y GOYAL, A. (2008). A comprehensive look at the empirical performance of equity premium prediction. *The Review of Financial Studies*, 21(4), pp. 1455-1508.

CAPÍTULO VI

Aprendizaje automático aplicado a la compraventa de criptomonedas

Gian Pietro Enzo Bellocca*

En los últimos años, las criptomonedas se han convertido en un nuevo activo financiero, atrayendo el interés especialmente de los pequeños inversores privados. Estudios recientes muestran que este nuevo mercado es particularmente inestable y propenso a anomalías de precio como el efecto *momentum*. Este trabajo tiene como objetivo proporcionar una visión general de la tecnología *blockchain* y cómo ha llevado al nacimiento de una nueva moneda digital. Posteriormente, se centra en la predicción y explotación del efecto *momentum* durante la actividad de inversión, centrándose en los períodos recientes de mercado alcista (2021) y de crisis (2022). En concreto, los modelos de aprendizaje automático pueden predecir, mediante el análisis de grandes bases de datos, la volatilidad de los precios a corto plazo, aumentando el rendimiento de la inversión en comparación con los enfoques tradicionales.

Palabras clave: *blockchain*, criptomonedas, aprendizaje automático, comercio de criptomonedas.

* El autor agradece a la profesora Pilar Poncela el apoyo brindado para la realización de este trabajo.

1. INTRODUCCIÓN AL MERCADO DE LAS CRIPTOMONEDAS

Las criptomonedas son un mercado joven y poco estructurado que tiene características y comportamientos muy distintos de los que se encuentran en los mercados tradicionales, donde se negocian productos como acciones, bonos, divisas, materias primas y derivados. Antes de introducir el concepto de criptomoneda y explorar las peculiaridades de su mercado, en este capítulo se presentan las principales características de las monedas fiduciarias (fiat), de los pagos electrónicos y de la cadena de bloques (*blockchain*), que han llevado al nacimiento de esta nueva forma de moneda digital.

1.1. La moneda fiduciaria

Una moneda es una unidad económica de valor que funciona como un medio de intercambio reconocido en una economía. Con el fin de realizar su tarea de la manera más eficiente posible, una moneda debe poseer características precisas como ser fungible, duradera, portátil, reconocible y estable. Inicialmente, la moneda, en forma de dinero, tomó la forma de una moneda compuesta por metales preciosos, como el oro y la plata. Por lo tanto, el valor de cada moneda era dado por la cantidad de metal precioso de la que estaba compuesta la misma moneda. Posteriormente se introdujo un tipo de moneda en papel, cuyo valor estaba representado por un bien material llamado subyacente, que a menudo era un metal precioso. Esto permitió facilitar enormemente el transporte y, por lo tanto, el intercambio de dinero. Más tarde, el 15 de agosto de 1971, con el fin de los acuerdos de Bretton Woods sobre la convertibilidad del dinero en oro, terminó la era del dinero basado en subyacente y comenzó la del dinero fiduciario.

El dinero fiduciario es una moneda emitida por un organismo gubernamental, que no está respaldada por una mercancía física como el oro o la plata, sino más bien por una autoridad central. A diferencia de la forma anterior de dinero, cuyo valor se define por el valor del subyacente, el valor del dinero fiduciario se deriva de la relación entre la oferta y la demanda y de la estabilidad del gobierno emisor. Muchas monedas actuales son monedas fiduciarias, como el dólar estadounidense, el euro y muchas otras monedas mundiales importantes. El dinero fiduciario toma principalmente la forma de dinero efectivo, generalmente monedas y billetes que, cuando se transfieren a otra persona, formalizan automáticamente la transferencia del valor que representan, sin la necesidad de involucrar a un tercero en la transacción. En efecto, la principal ventaja del efectivo reside en el hecho de que su posesión certifica también la posesión del valor que representa. Además, el efectivo permite a cualquiera participar en el sistema de pagos, sin barreras ni exclusiones. Entre las desventajas, sin embargo, encontramos la necesidad de estar físicamente presentes en el momento de la transacción, el alto riesgo de robo y falsificación y la dificultad en el seguimiento de los pagos por parte de los organismos de control financiero y fiscal.

Como se mencionó anteriormente, las monedas fiduciarias tradicionales necesitan un sistema centralizado y una figura de garantía, como gobiernos y bancos centrales, que pue-

dan garantizar el valor del dinero y gestionar su emisión. Un ejemplo es el euro, gestionado por varios organismos institucionales, entre ellos el Banco Central Europeo (BCE), encargados de su correcto funcionamiento. En particular, los países que han adoptado la moneda común europea han encomendado al BCE la ejecución de la política monetaria, que consiste en aumentar o disminuir la emisión de dinero, con el objetivo de estimular el crecimiento económico y garantizar la estabilidad de precios manteniendo una baja inflación.

1.2. Pagos electrónicos

Un sistema de pago electrónico permite transferir dinero electrónicamente a través de los llamados *cash data files*. Este tipo de archivos permite acceder a las ventajas del dinero en efectivo, y también es capaz de moverse libremente en las redes electrónicas, lo que facilita el movimiento de dinero a través de transferencia bancaria, correos electrónicos o redes sociales, sin exigir a las dos partes interesadas que estén en el mismo lugar para realizar la transacción. Una de las mayores debilidades de estos archivos de datos es que se puede duplicar fácilmente y sin coste alguno (problema de doble gasto). Como resultado, no se pueden usar los datos en efectivo como un sistema de pago seguro y eficiente. Para superar este problema, los sistemas de pago electrónico se basan en una autoridad centralizada, normalmente un banco, que verifica la legalidad de los pagos y realiza un seguimiento del estado de las distintas cuentas bancarias y de su valor monetario. En este tipo de sistema de transferencia de dinero, cuando un comprador inicia un pago enviando un pedido, la autoridad centralizada se asegura de que el comprador tenga los fondos necesarios para la transacción y actualiza las cuentas de las dos partes involucradas. Sin embargo, un sistema de pago centralizado requiere fiabilidad y seguridad. Los agentes implicados deben confiar en la autoridad central a la que delegan el poder de mantener la contabilidad correctamente actualizada, sin tomar posesión del dinero. Además, los sistemas centralizados son vulnerables a ataques de *hackers* y fallos técnicos, por lo que, se deben garantizar que los fondos están seguros en todo momento.

1.3. Blockchain

La tecnología *blockchain* fue introducida en 2008 por un individuo o grupo de desarrolladores anónimos bajo el seudónimo de “Satoshi Nakamoto”, y consiste en un libro mayor digital descentralizado, que registra una serie de transacciones. Su nombre proviene de los términos *bloque* y *cadena* introducidos por Satoshi Nakamoto. De hecho, en una *blockchain*, todas las transacciones se agrupan en bloques que luego se encadenan secuencialmente. De esta manera, toda la cadena de bloques representa un registro completo de toda la historia de las transacciones.

En la cadena de bloques, cada bloque no solo contiene detalles sobre la transacción y su marca de tiempo (*timestamp*), sino también un valor aleatorio (*nonce*) y el valor *hash* del blo-

que anterior. Este valor *hash*, que consiste en una serie de longitud fija que identifica de forma única el bloque, se utiliza para verificar la integridad y la corrección de la cadena de bloques al almacenar los detalles de una transacción. El valor *hash* se produce utilizando una función *hash* criptográfica específica, que asigna datos de transacciones a una serie de longitud fija compuesta de números y letras. Por lo tanto, cualquier cantidad de datos siempre producirá una serie alfanumérica de la misma longitud, dependiendo de la función *hash* utilizada. Este sistema criptográfico permite evitar cualquier tipo de cambio fraudulento de datos dentro de los bloques, ya que cualquier tipo de cambio conduciría también a un cambio en los valores *hash* respectivos. Para añadir un nuevo bloque a la cadena es necesario que las transacciones contenidas en el bloque y el bloque sean verificadas por la mayoría de los nodos descentralizados que forman la red, a través de un mecanismo de consenso. Este mecanismo garantiza que toda la información que se agregará sea válida y establece las reglas que los nodos deben seguir para llevar a cabo las verificaciones necesarias. Prueba de trabajo (*Proof of Work – PoW*) es el mecanismo de consenso más popular, en el que se basa el algoritmo *Hash Cash*, utilizado por varias criptomonedas, incluido bitc in. Con este algoritmo, un nuevo bloque se valida a trav s de un proceso de extracci n (*mining*), que recompensa al primer nodo que resuelve un problema matem tico complejo. En el caso de las criptomonedas, el premio consiste en una nueva moneda generada o una porci n de ella. La probabilidad de verificar un nuevo bloque y recibir la recompensa depende de la capacidad del nodo extractor, llamado *minero*, en resolver el problema matem tico. Este problema complejo consiste en encontrar un valor aleatorio (*nonce*) que, combinado con el valor *hash* de las transacciones y el encabezado del bloque anterior, produce un valor dado preciso. Cuando uno de los nodos encuentra una posible soluci n al problema, lo env a a los otros nodos de la red, que luego pueden verificarlo. Si la mayor a de los nodos est n de acuerdo con el resultado, el bloque se verifica y se agrega a la cadena de bloques. El nodo que produjo la soluci n es recompensado posteriormente. Cuanto m s tiempo pasa usando *PoW*, mayor es la dificultad en la extracci n, lo que conduce a una mayor dificultad para que los *mineros* obtengan la recompensa. Por lo tanto, los *mineros* se enfrentan a altos costes con objeto de poseer el mejor *hardware* para vencer a la competencia y a los costes de la electricidad. Otro mecanismo de consenso popular es la prueba de participaci n (*Proof of Stake – PoS*), en la que la capacidad de validar un bloque de transacci n depende de la cantidad de criptomonedas que posee el *minero*. Por lo tanto, este protocolo recompensa a los *mineros* no por su esfuerzo para resolver problemas matem ticos, sino por la cantidad de moneda acumulada por el nodo. Cuanto mayor sea la cantidad, mayor ser  la potencia de miner a.

Otra caracter stica importante de la tecnolog a *blockchain* es el cifrado asim trico, que permite al usuario proteger su propiedad digital y transferir informaci n cifrada. Todos los miembros de la cadena de bloques tienen dos claves, una privada y otra p blica. La primera, visible solo para el propietario, permite acceder a la cuenta espec fica del usuario y se utiliza como firma digital para las transacciones. La segunda es la direcci n de una cuenta individual. Para entender mejor el concepto de claves, podemos tomar como ejemplo el correo electr nico. En este caso, la clave p blica representa la direcci n de correo electr nico de un usuario, mientras que la clave privada es la contrase a para acceder a esa cuenta de correo electr nico espec fica. Al conocer la direcci n de un usuario, se le puede enviar un

correo electrónico, pero para acceder a una cuenta específica y enviar correos electrónicos desde ella también se debe conocer su contraseña. Del mismo modo en la cadena de bloques, al conocer la clave pública, se pueden enviar criptomonedas a esa cuenta específica, pero para acceder a ella o enviar criptomonedas desde ella, se debe conocer la clave privada relacionada, que pertenece a un propietario específico. Las claves públicas y privadas de un usuario se guardan en un monedero digital, en línea (*hot storage*) o fuera de línea (*cold storage*).

La cadena de bloques ofrece muchas ventajas sobre un sistema de pago normal, pero también tiene algunas desventajas que deben tenerse en cuenta. La principal ventaja es, sin duda, el sistema descentralizado que permite transacciones fiables sin la necesidad de un tercero. El sistema distribuido también permite una mejor tolerancia a los errores y una mayor resistencia a los ataques. Además, la cadena de bloques permite transacciones más rápidas con menores costes que los sistemas tradicionales, así como el acceso completo a todo el historial de transacciones de la red, de una manera totalmente transparente para sus usuarios. En cuanto a las desventajas, sin duda, la mayor es la actividad de extracción. Como ya se ha descrito anteriormente, esta última requiere inversiones en *hardware* cada vez más avanzado y unos costes energéticos elevados. Otro gran problema es la seguridad. En caso de pérdida de la clave privada del usuario, ya no será posible acceder a la correspondiente cuenta, y los recursos depositados se perderán para siempre. Además, una vez que se envía una transacción, no puede cancelarse para recuperar los recursos enviados. La transparencia total también puede tener un impacto negativo en la privacidad y la reputación del usuario, ya que todos pueden acceder al historial de toda la red. Por último existe el riesgo económico debido a la naturaleza volátil de las criptomonedas, lo que las convierte en una herramienta débil para usar como reserva de valor.

1.4 El mercado de las criptomonedas

En los últimos treinta años se han propuesto varias alternativas para los sistemas de pago. En la década de 1990, Digicash Inc introdujo *eCash*, que se considera la primera moneda digital similar a las criptomonedas modernas; sin embargo, no superó la burbuja de internet de principios de la década de 2000. Soluciones más modernas fueron propuestas por PayPal, Google y Apple, pero todos estos sistemas digitales siempre se basan en monedas fiduciarias, y se utilizan principalmente para compras en línea en plataformas de comercio electrónico o para la gestión de tarjetas bancarias. De manera diferente, las criptomonedas se presentan como un nuevo instrumento financiero viendo también la primera y más conocida aplicación de la tecnología *blockchain*. Aprovechando esta nueva tecnología, se ha construido un sistema de pago distribuido disponible en internet, que proporciona la integridad de las transacciones, sin necesidad de una autoridad central. Este sistema de pago descentralizado se utiliza como una red de intercambio directo para esta nueva forma de dinero digital, y no solo como una forma de comprar en línea. Con más de 3.000 monedas y una capitalización global del mercado de más de 1 billón de dólares, el mercado de las criptomonedas se ha convertido en una importante realidad financiera. La primera moneda

introducida es bitcoin que ocupa una cuota de mercado del 38 % del total¹. A continuación, en el **cuadro 1**, se muestra una breve lista² de las diez principales criptomonedas basadas en la capitalización de mercado.

Cuadro 1.

Top 10 criptomonedas por capitalización de mercado en fecha 19/11/2022

Rango	Criptomoneda	Precio	Capitalización de mercado	Monedas en circulación
1	Bitcoin	\$ 16.641,67	\$ 319.673.440.976	19.211.512
2	Ethereum	\$ 1.207,65	\$ 147.748.194.141	122.373.866
3	Tether	\$ 1,00	\$ 65.891.584.463	65.944.935.626
4	USD Coin	\$ 1,00	\$ 44.386.336.278	44.378.144.428
5	BNB	\$ 270,72	\$ 43.308.820.429	159.973.276
6	Binance USD	\$ 1,00	\$ 22.876.078.976	22.872.131.211
7	XRP	\$ 0,3795	\$ 19.094.085.360	50.298.735.565
8	Cardano	\$ 0,324	\$ 11.149.733.980	34.411.552.943
9	Dogecoin	\$ 0,08396	\$ 11.138.768.715	132.670.764.300
10	Polygon	\$ 0,8609	\$ 7.517.278.844	8.734.317.475

Con la llegada de bitcoin se desarrolló considerablemente el mercado de las criptomonedas, tanto en términos de activos negociados como en el número de inversores y empresas que operan en él. A largo plazo, el precio de bitcoin, así como el de otras criptomonedas, ha aumentado constantemente, aunque el mercado ha estado sujeto a varios períodos de burbuja seguidos de otros tantos de crisis. Estas han provocado la desaparición de varias criptomonedas y empresas que operan en el mercado. Las diferentes monedas intercambiadas difieren en el tipo de cadena de bloques adoptada y su utilización final. Por ejemplo, en los últimos años se han introducido varias monedas estables (*stablecoins*), que tienen como objetivo facilitar las actividades de intercambio y proteger contra la alta volatilidad del mercado, vinculando el valor de la moneda estable con el de las monedas fiduciarias u otros activos. Otras, como ethereum, se han convertido en la base para plataformas de contratos inteligentes (*smartcontracts*), lo que ha llevado al desarrollo de mercados secundarios como el de los *non-fungible tokens* (NFT). Otras nacieron por pura diversión y con fines humorísticos, pero fueron capaces de hacerse con una gran parte del mercado, creando una categoría aparte, la de las *meme-coins*. Las dificultades iniciales de acceso al mercado, debido a la creación y uso de una billetera encriptada, se han superado gracias a la aparición de numerosas plataformas de intercambio, que permiten poseer e intercambiar criptomonedas de manera más fácil y rápida. Estas plataformas, aunque han hecho que el mercado sea más estructurado y accesible, no siempre lo han hecho más estable. Dichas plataformas han permitido la entrada de numerosos pequeños inversores, más interesados en las posibilidades especulativas que en invertir en una nueva clase de activos y en nuevas tecnologías. Muchas plataformas también han estado sujetas a fallos de seguridad que han llevado al robo de dinero, propiedad de usua-

¹ Fuente: www.coin360.com

² Fuente: www.coinmarketcap.com

rios registrados. Además, al estar poco reguladas, las empresas propietarias de intercambios tienden a realizar también una gestión especulativa, poniendo en riesgo los depósitos de los usuarios en tiempos de crisis del mercado. El crecimiento de estas compañías y su gran interconexión mediante la posesión cruzada de criptomonedas propietarias (BNB, FTT token, OKB, KuCoin, HT, CRO) y monedas estables también ha aumentado enormemente el riesgo sistémico del mercado de las criptomonedas. Por ejemplo, el reciente colapso de la plataforma FTX, a través de la depreciación de su criptomoneda FTX token (FTT), ha afectado a varios fondos de inversión y a compañías de cambio de moneda. Otro ejemplo reciente involucró a la moneda estable terraUSD. La empresa en gestión no pudo mantener el valor de la moneda estable vinculada al dólar estadounidense debido a un ataque especulativo. Esto llevó a la depreciación del valor de terraUSD, causando grandes pérdidas entre los inversores y las plataformas que la utilizaban. Todos estos problemas hacen que el mercado de las criptomonedas sea extremadamente inmaduro y particularmente arriesgado. La alta volatilidad, las quiebras y el fraude todavía lo hacen poco adecuado para actividades de inversión tradicionales y a largo plazo, siendo más adecuado para especulaciones a corto plazo.

2. EFECTO *MOMENTUM* EN LOS MERCADOS FINANCIEROS

En este capítulo se proporciona una introducción del efecto *momentum* en los mercados financieros y, en particular, en el mercado de las criptomonedas. Además, en los apartados siguientes se analizan algunos modelos para explotarlo durante la actividad de inversión.

El funcionamiento y las causas del efecto *momentum* en los mercados financieros debe buscarse en el método con el que se determinan los precios de los productos financieros según las dos teorías principales, la de las finanzas tradicionales y la de las finanzas conductuales. La teoría de las finanzas tradicionales utiliza una serie de hipótesis que definen el comportamiento de los inversores y las condiciones en las que operan, con el fin de comprender la dinámica y dar forma al funcionamiento de los mercados financieros. Esta teoría afirma que los inversores se oponen al riesgo, tienen acceso completo a la información sobre los mercados y toman decisiones racionales para maximizar los beneficios, sin ser influenciados por otros factores. Además, los modelos basados en esta teoría requieren un mecanismo de arbitraje eficiente, que permita que el precio de los productos financieros permanezca anclado en el valor de equilibrio, corrigiendo rápidamente cualquier cambio. Muchas de las hipótesis en las que se basan las finanzas tradicionales a menudo son poco realistas, ya que suponen un mercado ideal. En la década de los ochenta, un gran número de investigadores e inversores comenzaron a encontrar una serie de resultados empíricos incompatibles con el equilibrio de precios y los modelos de mercado eficientes. Estos hallazgos llevaron al desarrollo de una nueva teoría para fijación de precios llamada finanzas conductuales. Más concretamente, el nuevo modelo de comportamiento intenta explicar las anomalías detectadas basándose en dos pilares fundamentales. El primer pilar, relativo a la psicología del inversor, afirma que los operadores en los mercados no actúan racionalmente. A diferencia de los modelos financieros tradicionales, el inversor se ve afectado por algunos prejuicios (sesgo) y de la información que recibe. El segundo pilar, por el contrario, defiende la ineficacia del sistema de arbitraje, reconociendo así la posibilidad de una desviación prolongada de los precios de su valor de equilibrio.

Entre las anomalías estudiadas por las finanzas conductuales está también el efecto *momentum*, que consiste en la autocorrelación positiva de los precios. Esto, por ejemplo, puede ocurrir durante un mercado alcista, donde el aumento de los precios empuja a los inversores a comprar para especular (*fear of missing out*). Del mismo modo, durante un período de crisis y bajada de precios, los inversores se ven presionados a vender para tratar de contener las pérdidas, empujando así los precios cada vez más bajos. Se han encontrado pruebas de este mecanismo en los principales mercados, empezando por el estadounidense (Jegadeesh y Titman, 1993). También, Lansdorp y Jellema (2013) observaron un comportamiento similar en el mercado de valores durante la burbuja de las empresas. El alto nivel de especulación alcanzado durante la burbuja también atrajo el interés de los pequeños inversores, quienes poco informados sobre los productos y servicios en los que estaban invirtiendo, compraban las acciones de las empresas tecnológicas atraídos por las altas ganancias realizadas. Además, Rouwenhorst (1999) muestra cómo la dificultad para obtener información hace que los mercados emergentes sean particularmente vulnerables al efecto *momentum*.

2.1. Evidencia del efecto *momentum* en el mercado de las criptomonedas

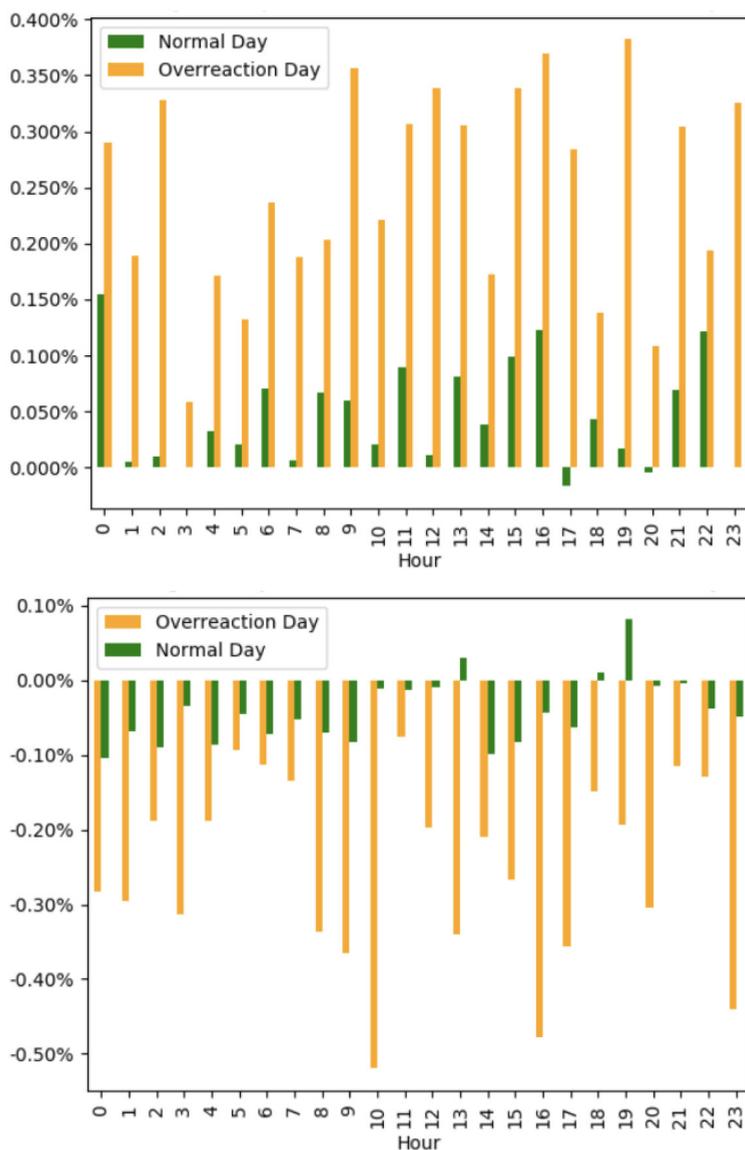
El mercado de las criptomonedas es un caso nuevo y relativamente inexplorado de mercado muy vulnerable a las anomalías descritas por las finanzas conductuales. Esto se debe a su alta volatilidad en comparación con los mercados tradicionales. Estudios recientes han analizado su eficiencia, las propiedades de memoria larga y la persistencia de los precios (Bartos, 2015; Urquhart, 2016; Bariviera, 2017), la existencia de burbujas (Corbet, Lucey y Yarovaya, 2018), su competitividad (Gandal y Halaburda, 2014), la predictabilidad de los precios (Plastun *et al.*, 2021) y la presencia de anomalías (Kurihara y Fukushima, 2017).

La influencia del efecto *momentum* en el mercado de las criptomonedas se debe a sus afinidades con los mercados emergentes, como la baja regulación y la falta de información confiable. Esto hace que las grandes instituciones financieras no tengan la autorización o el interés de operar en este mercado, dejándolo principalmente en manos de pequeños fondos o individuos. Además, la complejidad de los activos negociados a menudo no permite invertir de manera consciente. Los inversores con menos experiencia, al encontrar extremadamente complicado desarrollar su propio análisis de la evolución de los precios, se dejan guiar por los rumores y el deseo de especular, y no por un interés real en las tecnologías *blockchain*. Algunos estudios recientes se han centrado en el efecto *momentum* y la volatilidad de los precios en el mercado de las criptomonedas. Chevapatrakul y Mascia (2019), basándose en el modelo autorregresivo, muestran que los inversores están listos para abandonar el mercado en los días en que los precios tienden a caer, y a realizar compras masivas durante las semanas en que los precios están en fuerte aumento. Sin embargo, no se han encontrado resultados significativos durante períodos más largos, lo que sugiere que el mercado de las criptomonedas se caracteriza por una dinámica mucho más rápida que los mercados en los que se negocian activos tradicionales. Más tarde, Caporale y Plastun (2020) muestran la presencia de patrones en la evolución de los precios de las criptomonedas como resultado de una reacción de precios

excesiva, llamada *sobrerreacción* (*overreaction*). En particular, como consecuencia de una reacción positiva o negativa excesiva, los precios tienden a aumentar o disminuir más durante ese mismo día y, en algunos casos, también durante parte del día siguiente, mostrando rastros

Figura 1.

Rendimiento horario promedio de bitcoin en días de reacción excesiva (positiva y negativa) y en días normales en el período comprendido entre 2015 y 2019



de un efecto *momentum* a corto plazo. Además, se ha identificado la posibilidad de detectar los días atípicos antes del final del día, y así poder aprovechar el siguiente efecto *momentum* para obtener un beneficio. El sistema de seguimiento utiliza un comportamiento inusual de los rendimientos por hora durante los días en que se produce una reacción excesiva de los precios. Específicamente, en días de reacción excesiva positiva o negativa, los rendimientos por hora son significativamente más altos o bajos que los rendimientos por hora alcanzados durante los días considerados normales.

La **figura 1** muestra este comportamiento para bitc on, comparando los rendimientos horarios medios de los d as normales y de los d as caracterizados por una reacci n excesiva.

3. MODELOS PARA LA EXPLOTACI N DEL EFECTO *MOMENTUM* EN LA ACTIVIDAD DE INVERSI N

Este cap tulo presenta dos modelos para la predicci n del efecto *momentum* que sigue una reacci n excesiva del precio de las criptomonedas. Estos modelos son basados en los hallazgos que se muestran en la secci n 2 y se utilizan como estrategias en la actividad de inversi n. El primero es un enfoque heur stico propuesto por Caporale y Plastun (2020). El segundo utiliza el aprendizaje autom tico para desarrollar una nueva estrategia de inversi n que aumente la eficiencia y rentabilidad de la anterior desarrollado por Bellocca *et al.* (2022).

3.1. El enfoque heur stico

El m todo de detecci n de la reacci n excesiva de los precios propuesto por Caporale y Plastun (2020) es un m todo heur stico basado en la inspecci n horaria de los precios de las criptomonedas. La detecci n se lleva a cabo mediante el uso de dos umbrales de precio predefinidos, que tambi n sirven para activar las operaciones comerciales.

Los umbrales adoptados en el m todo heur stico se calculan utilizando el rendimiento medio diario de la criptomoneda y su desviaci n est ndar. Los rendimientos diarios (R_i) se calculan como sigue:

$$R_i = (Close_i / Open_i - 1) * 100 \% \quad [1]$$

donde R_i es el rendimiento del d a i en %, $Open_i$ es el precio de apertura del d a i y $Close_i$ es el precio de cierre del d a i . Los dos umbrales se calculan para cada d a de funcionamiento utilizando datos hist ricos. Para ello, los datos se dividen en d as de rendimiento positivo y negativo. Los dos subconjuntos se utilizan para calcular los umbrales de precio positivo y negativo, respectivamente. El d a i se caracterizar  por una reacci n excesiva positiva si:

$$R_i > (R_n + k * \sigma_n) \quad [2]$$

y se caracterizará por una reacción excesiva negativa si:

$$R_i < (R_n - k * \sigma_n) \quad [3]$$

donde R_n es el rendimiento diario medio durante n días, σ_n es la desviación típica durante n días y k es un número positivo que indica de desviaciones típicas que estamos considerando para definir los umbrales.

El rendimiento diario medio y la desviación típica para un período de n días se calcularán como sigue:

$$R_n = \sum_{i=1}^n \frac{R_i}{n} \quad [4]$$

$$\sigma_n = \sqrt{\frac{1}{n} \sum_{i=1}^n (R_i - R_n)^2} \quad [5]$$

El método heurístico compara el precio actual con los umbrales para asignar el día de negociación actual a una de las siguientes categorías: reacción excesiva positiva, reacción excesiva negativa o día normal. Para hacerlo, realiza una comprobación de precio por hora a fin de detectar si el precio de la criptomoneda considerada es superior a uno de los dos umbrales calculados diariamente. Si el precio supera un umbral determinado, el día actual se clasifica con la etiqueta de reacción excesiva correspondiente. Al final del día, una predicción es correcta si el precio de cierre diario todavía está por encima del nivel de umbral. El sistema de *trading* propuesto por Caporale y Plastun (2020) utiliza estas lecturas para abrir posiciones largas o cortas si el umbral superado es positivo o negativo, respectivamente. Todas las posiciones se cierran al final del día.

3.2. El enfoque de aprendizaje automático

El término aprendizaje automático fue introducido por Arthur Samuel en los años 50 para describir tareas de reconocimiento de patrones. A partir de ese momento, el uso práctico de las técnicas de aprendizaje automático ha abarcado varios sectores, especialmente el económico y financiero, gracias a su capacidad de analizar grandes cantidades de datos, incluso aquellos poco estructurados. Entre las diversas aplicaciones encontramos el análisis de documentos legales y datos bancarios internos para resolver problemas de cumplimiento bancario, combatir el fraude y prevenir el lavado de dinero. Un segundo ámbito de aplicación es el relativo a la gestión del cliente. De hecho, utilizando el aprendizaje automático, los bancos y las instituciones financieras han desarrollado *chatbots* y *robo-advisor* capaces de mejorar el servicio al cliente y ofrecer servicios para la creación y gestión automática de una cartera de inversión. Otra aplicación es la gestión de riesgos, tanto la de mercado, mediante las previsiones de la evolución de los precios, como la de crédito, mediante el análisis de la situación financiera de los solicitantes de préstamos. La última aplicación importante es, sin duda, la

actividad de inversión. Los complejos sistemas informáticos implementados por bancos y fondos consiguen que las decisiones de *trading* sean extremadamente rápidas, llegando a realizar millones de operaciones diarias (*high frequency trading*). Estas decisiones implican el uso del aprendizaje automático, por ejemplo, mediante el análisis de sentimientos aprovechando enormes cantidades de noticias de artículos, blogs y sitios web, redes sociales y archivos multimedia como videos y audios. Varios estudios académicos han analizado la posibilidad de aprovechar las técnicas de aprendizaje automático para predecir la evolución de los precios en el mercado de valores (Bustos y Pomares-Quimbaya, 2020; Huang *et al.*, 2019; Ozbayoglu, Gudelek y Sezer, 2020; Rundo *et al.*, 2019), pero pocos trabajos han intentado reutilizar los sistemas comerciales modernos en el mercado de las criptomonedas. Un ejemplo es Attanasio *et al.* (2019), que han estudiado la aplicación de algunas técnicas de clasificación (*Support Vector Machine* y *Decision Trees*) para predecir el precio de las criptomonedas durante el día siguiente a la predicción. Otros estudios (Lahmiri y Bekiros, 2021; Livieris *et al.*, 2020) se centraron en las técnicas de aprendizaje profundo (*Deep learning*), explorando diferentes tipos de datos de entrada, como información económica financiera o información relacionada con la *blockchain* en la que se apoya la criptomoneda analizada. Otra serie de trabajos investiga el uso de enfoques ensemble como *Random Forests* y *Stochastic Gradient Boosting Machine* (Derbentsev *et al.*, 2021) y el algoritmo *Gradient Boosting Decision Tree* (Sun, Liu y Sima, 2020). Por último, algunos estudios han utilizado técnicas de minería de texto usando datos de redes sociales, tales Twitter (Kraaijeveld y De Smedt, 2020) o GitHub y Reddit (Glenski, Weninger y Volkova, 2019) para predecir los precios de las principales criptomonedas. Sin embargo, todas las estrategias anteriores se caracterizan típicamente por un alto grado de ruido, lo que hace que el proceso de inferencia sea complejo y no sea fácil de explicar.

Bellocca *et al.* (2022), a diferencia de los trabajos anteriores en los que se investigaba la posibilidad de predecir los precios de las criptomonedas a corto plazo, proponen una nueva estrategia basada en el aprendizaje automático para prever la aparición de una reacción excesiva. El enfoque propuesto aprovecha las propiedades del mercado destacadas por recientes evidencias empíricas (Caporale y Plastun, 2020) junto con el poder predictivo de los modelos de aprendizaje automático, para contrarrestar la mayor desventaja del método heurístico, es decir, la generación de señales comerciales falsas. El objetivo es, otra vez, prever si un día de actividad se caracteriza por una reacción excesiva de los precios, de modo que pueda utilizarse esta información durante la actividad de inversión. A diferencia de la estrategia heurística, que realiza una inspección horaria del precio para detectar una reacción excesiva y generar señales, la estrategia de aprendizaje automático utiliza datos de granularidad diaria para hacer una predicción sobre el siguiente día de actividad. El modelo propuesto es el siguiente:

$$O_c(d_{i+1}) = f_c(S_c(d_i), S_c(d_{i-1}), \dots, S_c(d_{i-W+1})) \quad [6]$$

donde $f_c()$ es la función de predicción y O_c es el indicador que se quiere predecir. Específicamente, O_c indica si el día de operación d_{i+1} para la criptomoneda c es un día de reacción excesiva, positiva o negativa, o un día con una tendencia de precios normal. Los datos de entrada utilizados por el modelo son un conjunto de datos históricos, que describen c durante el día actual d_i , en el que se hace la predicción, y los días anteriores $d_{i-1}, d_{i-2}, \dots, d_{i-W+1}$. W indica

el tamaño de la ventana de datos históricos utilizados para la predicción. Para generar las etiquetas de clase O_c correctas, útiles para entrenar y verificar la precisión del clasificador, se utilizan los valores umbral definidos por Caporale y Plastun (2020). Para generar los valores umbral se ensayaron diferentes valores de W , comprendidos en el intervalo $[50,360]$ días, y de k , incluidos en el intervalo $[0,2]$. Los datos de entrada utilizados para entrenar al clasificador no se limitan sólo a los precios y volúmenes históricos de negociación. De acuerdo con Attanasio, Cagliero y Baralis (2020), las variaciones de precios diarias se describen con una serie de indicadores técnicos preestablecidos (Murphy, 1999), con el fin de resumir el estado y las tendencias de la criptomoneda. El conjunto de los 22 indicadores técnicos utilizados tiene como objetivo señalar si el precio de la criptomoneda está siguiendo una tendencia, evaluar la fuerza de esta tendencia y detectar evidencia de efecto *momentum*.

Finalmente, la estrategia de *trading* basada sobre el enfoque que utiliza el aprendizaje automático difiere de la que se basa en el método heurístico. En este caso, al disponer de la etiqueta diaria desde el inicio del día, se abren inmediatamente las posiciones correspondientes sin realizar un análisis de los precios por hora para la generación de señales de compra o venta. Todas las operaciones se cierran al final del día, como en la estrategia heurística.

4. APLICACIÓN EMPÍRICA

Este apartado presenta la aplicación empírica. Después de mostrar la metodología utilizada en Bellocca *et al.* (2022) para comparar la eficiencia del modelo heurístico y el modelo basado en aprendizaje automático, se presenta la aplicación empírica de este trabajo. El objetivo es ampliar el análisis realizado anteriormente, proporcionando una evaluación más exhaustiva de los resultados de la predicción y la inversión en diferentes condiciones de mercado.

4.1. Estrategias previas

Bellocca *et al.* (2022) comparan los resultados obtenidos replicando el enfoque heurístico de Caporale y Plastun (2020) y los obtenidos con diferentes clasificadores de aprendizaje automático a través de extensas pruebas retrospectivas. Para ello, recopilan datos históricos diarios³ sobre un conjunto de criptomonedas que luego dividen en dos intervalos de tiempo. El primer intervalo de datos se utiliza para entrenar los modelos de aprendizaje automático, proporcionando información sobre los indicadores técnicos y la clasificación correcta de la reacción excesiva para cada día de actividad que contiene. La parte restante de los datos se utiliza para la evaluación de los diferentes modelos, comparándolos también con los resultados obtenidos siguiendo la estrategia heurística de Caporale y Plastun (2020). El estudio incluye tres de las principales criptomonedas: bitc in (BTC), ethereum (ETH) y litecoin (LTC). Los intervalos temporales van del 2 de septiembre de 2015 al 31 de diciembre de 2019

³ Fuente: Kraken exchange APIs y www.cryptodatadownload.com

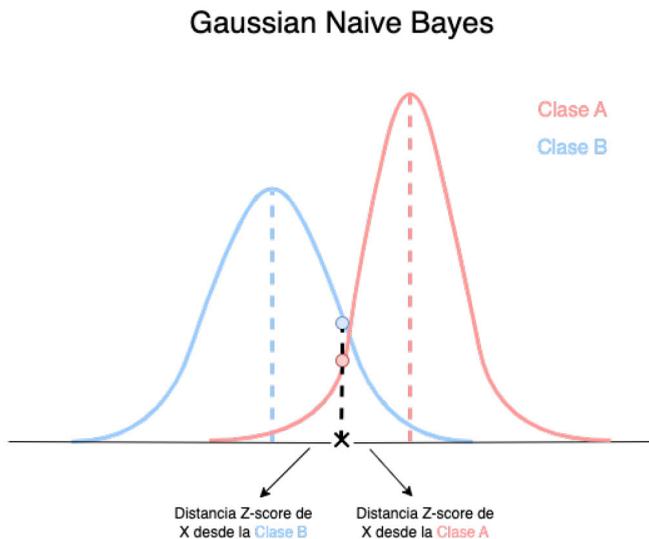
para el entrenamiento de modelos, y del 1 de enero de 2020 al 31 de diciembre de 2020 para la evaluación.

La predicción se configura, como se mencionó anteriormente, como una tarea de clasificación de tres clases, con el objetivo de predecir situaciones de reacción excesiva positiva o negativa o días neutros. Los algoritmos de clasificación considerados son los siguientes:

- **Multi-Layered Perceptron (MLP):** un *perceptrón* multicapa (MLP) es una clase completamente conectada de red neuronal artificial de retroalimentación. Está compuesto por al menos tres capas de nodos: una capa de entrada, una capa oculta y una capa de salida. A excepción de los nodos de entrada, cada nodo es una neurona que utiliza una función de activación no lineal. En el aprendizaje supervisado el entrenamiento se realiza a través de la retropropagación, una generalización del algoritmo de mínimos cuadrados medios.
- **Gaussian Naive-Bayes (GNB):** Naive Bayes es un grupo de algoritmos de clasificación de aprendizaje automático supervisados basados en el teorema de Bayes. *Gaussian Naive Bayes* soporta características de ingreso (*classification features*) de valor continuo y conforme a una distribución gaussiana (normal). El modelo se construye simplemente encontrando la media y la desviación estándar de los puntos dentro de cada clase. Luego, en cada punto de datos, se calcula el *z-score* (distancia entre ese punto y la media de clase dividida por la desviación estándar de clase) para asignar cada punto de datos a la clase más cercana.

Figura 2.

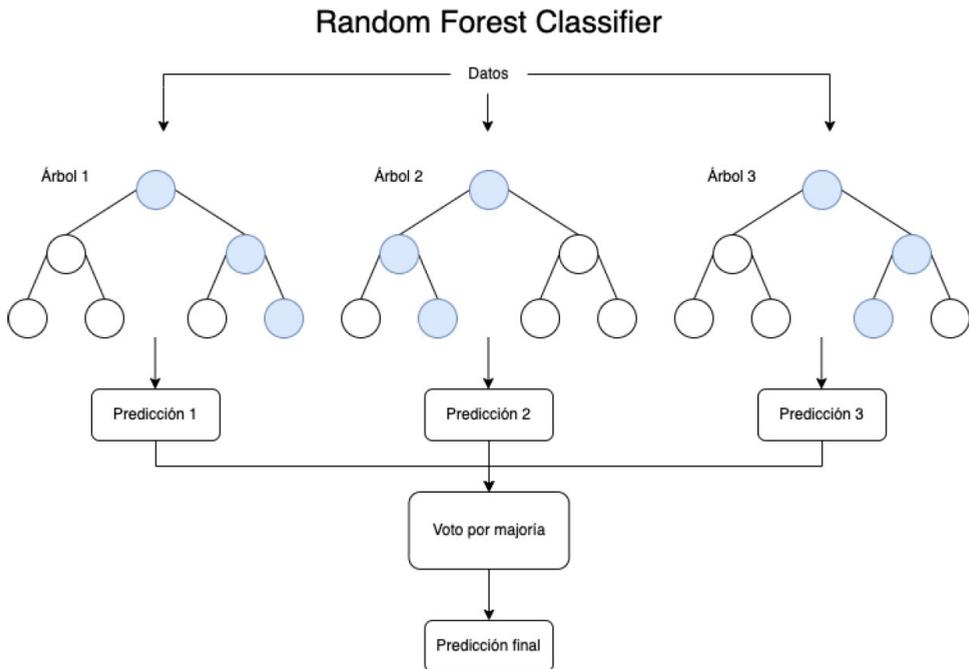
Ejemplo gráfico de clasificación utilizando GNB con dos clases



- **Multinomial Naive-Bayes (MNB):** este algoritmo es un método de aprendizaje probabilístico adecuado para la clasificación con características discretas. La distribución multinomial normalmente requiere conteos enteros, pero también puede trabajar con conteos fraccionarios.
- **Random Forest (RFC):** el bosque aleatorio (*Random Forest*) es un método de aprendizaje *ensemble* utilizado principalmente para la regresión y la clasificación, que opera construyendo una multitud de árboles de decisión durante la fase de formación. Su aplicación a problemas de clasificación se llama clasificador en bosque aleatorio (*Random Forest Classifier*), que consiste en un estimador que entrena a un número de clasificadores en árbol de decisión sobre varias submuestras del conjunto de datos disponible y utiliza el promedio para mejorar la precisión predictiva y controlar el sobreajuste (*overfitting*).

Figura 3.

Ejemplo gráfico de clasificación utilizando el bosque aleatorio con tres árboles de decisión

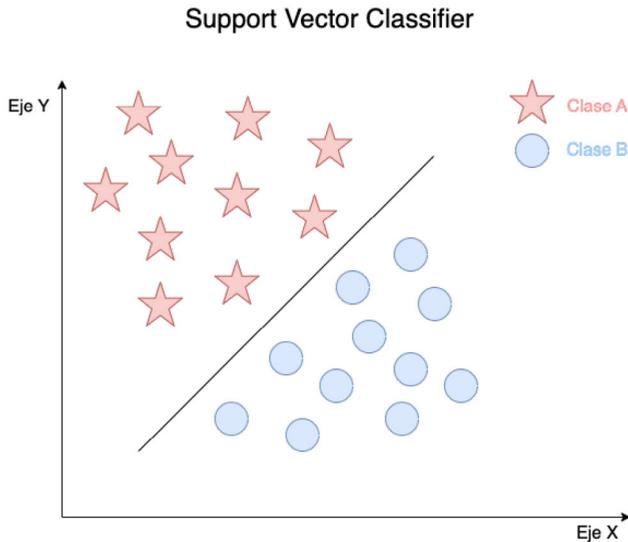


- **Support Vector Machine (SVM):** una máquina vectorial de soporte es un algoritmo de aprendizaje automático supervisado que se puede utilizar para tareas de clasificación y regresión. En la tarea de clasificación (*Support Vector Classifier*) funciona mapeando

puntos de datos a un espacio de alta dimensión y luego encontrando el hiperplano óptimo que divide los datos en dos clases, maximizando el margen entre las dos clases.

Figura 4.

Ejemplo gráfico de clasificación utilizando el SVC en dos dimensiones



- **Logistic Regressor (LG):** la regresión logística es un ejemplo de algoritmo de aprendizaje supervisado. Se utiliza para predecir la probabilidad de un resultado binario, como verdadero o falso, o resultado no binario (regresión logística multinomial), basado en observaciones previas de un conjunto de datos. En el caso de la clasificación binaria, la probabilidad siempre oscila entre 0 (falso) y 1 (verdadero) y se calcula utilizando una función sigmoide, utilizada para convertir datos en un valor entre 0 y 1.
- **K-Nearest Neighbors (KNN):** vecinos más cercanos (KNN) es un algoritmo de aprendizaje supervisado utilizado para la clasificación. Mediante el modelo KNN, un objeto se clasifica por un voto de pluralidad de sus vecinos, con el objeto asignado a la clase más común entre sus k vecinos más cercanos.

Para mejorar el rendimiento de la clasificación, se optimizan los parámetros de cada algoritmo de aprendizaje mediante búsqueda exhaustiva (*exhaustive grid-search*). La validación se realiza utilizando una validación cruzada dividiendo los datos en k fracciones (*k-fold cross-validation*), con un número de fracciones igual a 5. Por último, en la fase de prueba se

Figura 5.

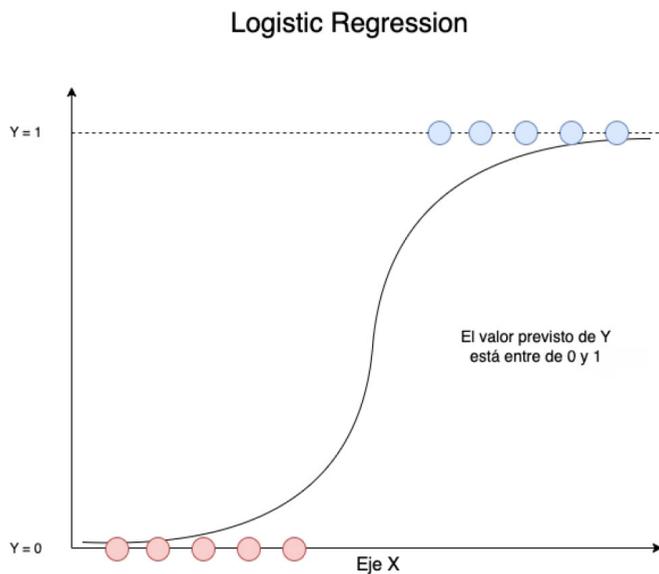
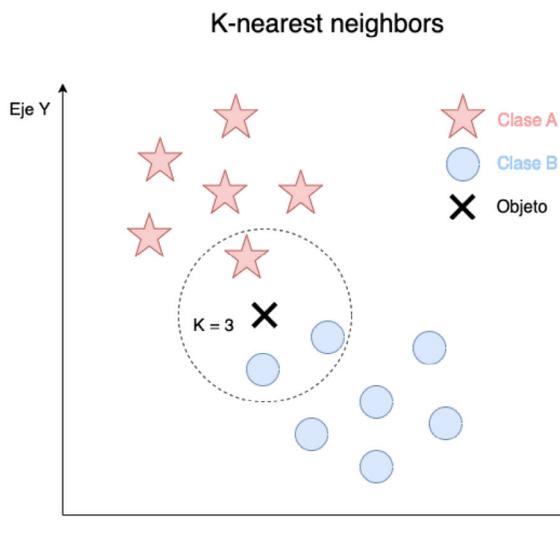
Ejemplo gráfico de clasificación utilizando la regresión logística binaria

Figura 6.

Ejemplo gráfico de clasificación utilizando el KNN con $k=3$ 

utiliza para cada algoritmo de aprendizaje la configuración más eficaz en términos de F1⁴ ponderada obtenida en la fase de validación.

4.2. Extensión de la aplicación empírica

Las pruebas realizadas por Bellocca *et al.* (2022) se centran solo en 2020, un año predominantemente poco agitado para el mercado de las criptomonedas. De hecho, solo en los últimos meses de este año, se ha producido un aumento en la volatilidad que ha llevado al precio de bitcóin a superar sus máximos históricos alcanzados tres años antes, en diciembre de 2017. La intención de este trabajo es probar los modelos presentados anteriormente, tanto heurístico como basado en el aprendizaje automático, en una etapa diferente del mercado. El período que va desde principios de 2021 hasta finales de 2022 brinda esta oportunidad, ya que se caracteriza por un fuerte mercado alcista antes, y un período de caída de precios posterior. En particular, el nuevo período de valoración se divide en dos partes, utilizando el 10 de noviembre de 2021, fecha del máximo histórico de bitcóin, como punto de división. Los dos períodos de evaluación son una fase alcista del mercado (del 1 de enero de 2021 al 10 de noviembre de 2021) y una fase bajista (del 11 de noviembre de 2021 al 20 de noviembre de 2022). Esta división permite estudiar la eficiencia de los métodos de previsión y la actividad de inversión en ambos escenarios de mercado.

En cuanto a la fase de entrenamiento del clasificador, se utilizan todos los datos disponibles antes del primer día de prueba. Por esta razón, el segundo segmento de prueba tiene un mayor intervalo de entrenamiento. Además, la mayor disponibilidad de datos para monedas nacidas después de bitcóin, ethereum y litecoin permite incluir otras monedas, como ripple (XRP), tron (TRX) y monero (XMR), a fin de ampliar la muestra a una parte más grande del mercado.

5. RESULTADOS

En este apartado se presentan los resultados obtenidos de los dos métodos, heurístico y de aprendizaje automático, tanto en la predicción de los días de reacción excepcional como en su eficiencia en una simulación comercial. Para empezar, se resumen brevemente los resultados derivados del trabajo anterior (Bellocca *et al.*, 2022) basado en los datos relativos al año 2020, a fin de compararlos posteriormente con los nuevos obtenidos analizando los dos años siguientes. También se presentan algunos resultados obtenidos mediante simulaciones de inversión cruzada, para analizar mejor la correlación de bitcóin con otras criptomonedas en períodos de alta volatilidad.

5.1. Resultados anteriores

Los resultados de predicción de reacciones de precios excesivas presentados por Bellocca *et al.* (2022) muestran que los métodos de aprendizaje automático superan el enfoque heu-

⁴ La puntuación F1 se define como la media armónica entre la precisión y el recuerdo. Se utiliza como medida estadística para evaluar el rendimiento de la clasificación.

rístico en términos de F1 ponderada, pero no hay un mejor método para todas las criptomonedas analizadas. Además, las simulaciones de inversión realizadas implican dos estrategias diferentes, como ya se ha mencionado anteriormente. En concreto, la estrategia de *trading* heurística realiza un control horario de los precios. Cuando el precio alcanza el umbral positivo o negativo, se abre una posición larga o corta correspondiente. En contraste, la estrategia de negociación basada en el aprendizaje automático no adopta el seguimiento horario de precios. Esta utiliza las etiquetas producidas por el clasificador para abrir una posición larga o corta dependiendo de si la etiqueta calculada al comienzo de cada día de negociación es positiva o negativa. Ambas estrategias cierran sus posiciones al final de cada día de negociación. Los resultados operativos de Bellocca *et al.* (2022) muestran que las estrategias basadas en el aprendizaje automático abren menos posiciones que la estrategia heurística, con un mayor porcentaje de operaciones rentables y, por lo tanto, reduciendo las pérdidas. Estos valores confirman que el método de detección basado en el aprendizaje automático es más eficaz para evitar la generación excesiva de señales, a pesar de que solo tiene datos anteriores al día operativo actual. Además, el rendimiento total y el rendimiento medio por operación obtenidos por las estrategias de aprendizaje automático son más altos. Esto se debe a que el aprendizaje automático permite abrir posiciones desde el comienzo de cada día de reacción excesiva, sin esperar a que el precio alcance uno de los dos niveles umbral. De esta manera es posible entrar en el mercado desde una mejor posición que la estrategia heurística, pudiendo así aprovechar no sólo el efecto *momentum*, sino también la reacción excesiva de precio que se manifiesta en ese día específico, aumentando los beneficios. Los mejores resultados operativos de las tres criptomonedas se obtienen mediante el uso de los algoritmos *KNN* y *SVC*, con rendimientos totales superiores al doble de los obtenidos con la estrategia heurística.

5.2. Nuevos resultados

Los resultados que se presentan a continuación se obtienen con nuevas pruebas a lo largo de dos fases diferentes del mercado: mercado alcista y mercado bajista. En las pruebas del primer período contemplado se incluyeron seis criptomonedas diferentes: BTC, ETH, LTC, XRP, TRX y XMR. Dado que los datos sobre las monedas más pequeñas (TRX y XMR) todavía no están disponibles para el segundo período, desafortunadamente, para estas últimas monedas no se pueden presentar los resultados durante el mercado bajista. Al igual que con el trabajo anterior, se prueban diferentes valores de W y k para generar umbrales, obteniendo nuevamente los mejores resultados con $W=50$ y $k=1$. A continuación se comentan los resultados obtenidos con esta configuración.

5.2.1. Predicción de reacciones excesivas

Los cuadros 2 y 3 muestran los resultados de la predicción de reacciones excesivas durante los dos períodos considerados. En cuanto al rendimiento en el mercado alcista (cuadro 2), se puede observar que la puntuación F1 está en línea con los valores registra-

dos para el año 2020 (>0.70), excepto en algunos casos. De hecho, GNB, SVC y LG muestran poca eficacia en la predicción de reacciones excesivas para BTC, ETH y TRX, con una drástica disminución en el valor ponderado de F1. En los demás casos, comparando el método heurístico con los algoritmos de clasificación se encuentran puntuaciones similares sin un mejor global. De lo contrario, si se observan los resultados en el mercado bajista (cuadro 3), se puede observar que estos son mucho mejores, con la puntuación F1 más alta obtenida siempre mediante el uso del aprendizaje automático. La caída de las puntuaciones en la fase alcista (2021) se debe a la diferente situación del mercado en el período de entrenamiento y evaluación. De hecho, antes de 2021, el mercado de criptomonedas nunca había alcanzado los niveles de precios y volatilidad como en ese año. Esta situación de volatilidad sólo se observó en 2017, cuando el mercado de las criptomonedas todavía estaba escasamente

Cuadro 2.

Valores de F1 ponderadas para cada modelo de clasificación por el mercado alcista

Modelo	BTC	ETH	LTC	XRP	TRX	XMR
HE	0,72	0,78	0,75	0,78	0,76	0,77
GNB	0,02	0,01	0,70	0,68	0,17	0,75
KNN	0,74	0,64	0,78	0,77	0,74	0,78
LG	0,48	0,37	0,77	0,79	0,14	0,80
MLP	0,59	0,58	0,68	0,76	0,45	0,73
MNB	0,75	0,77	0,78	0,80	0,76	0,78
RFC	0,74	0,72	0,76	0,80	0,72	0,79
SVC	0,24	0,01	0,70	0,75	0,20	0,75

Nota: Los mejores resultados para cada criptomoneda se indican en negrita. Los resultados iniciales del modelo heurístico están en cursiva.

Cuadro 3.

Valores de F1 ponderadas para cada modelo de clasificación por el mercado bajista

Modelo	BTC	ETH	LTC	XRP
HE	0,75	0,75	0,76	0,74
GNB	0,78	0,79	0,77	0,77
KNN	0,71	0,72	0,78	0,75
LG	0,78	0,77	0,80	0,76
MLP	0,72	0,72	0,76	0,72
MNB	0,78	0,77	0,78	0,76
RFC	0,75	0,78	0,79	0,76
SVC	0,66	0,63	0,78	0,76

Nota: Los mejores resultados para cada criptomoneda se indican en negrita. Los resultados iniciales del modelo heurístico están en cursiva.

poblado. Además, los umbrales se calculan en los 50 días anteriores, actualizando con mucho retraso los valores de media móvil y desviación estándar, a pesar de que el mercado presenta una dinámica muy rápida y una alta volatilidad. En contraste, en el siguiente período de valoración (2022), los modelos pueden contar con un período de entrenamiento que también incluye el período de alta volatilidad del mercado alcista (2021). De este modo, se pueden predecir mejor las reacciones de precios excesivas, incluso en un mercado de tendencia opuesta.

5.2.2. Resultados de las simulaciones de inversión

Los cuadros 4 y 5 presentan los resultados de las simulaciones de inversión correspondientes a los dos períodos considerados. En particular, para cada criptomoneda se proponen los resultados de la estrategia heurística y los dos mejores algoritmos de clasificación, evaluados en términos de operaciones rentables, rendimiento total y rendimiento promedio por operación.

Cuadro 4.

Resultados operativos en el mercado alcista

Moneda	Modelo	Inversiones	Inversiones rentables	Inversiones rentables %	Rendimiento total %	Rendimiento medio %
BTC	<i>HE</i>	37	21	55,76	-0,87	-0,02
	KNN	9	6	66,67	17,57	1,95
	SVC	258	134	51,94	58,56	0,23
ETH	<i>HE</i>	33	18	54,55	27,01	0,82
	MLP	137	73	53,28	124,06	0,91
	MNB	27	14	51,85	-14,71	-0,54
LTC	<i>HE</i>	33	19	57,58	0,73	0,02
	KNN	1	1	100,00	19,36	19,36
	SVC	74	47	63,51	100,68	1,36
XRP	<i>HE</i>	30	18	60,00	23,04	0,77
	MLP	35	24	68,57	89,21	2,55
	SVC	70	39	55,71	69,61	0,99
TRX	<i>HE</i>	34	16	47,06	4,08	0,12
	KNN	27	19	70,37	15,75	0,58
	SVC	271	157	57,93	104,36	0,39
XMR	<i>HE</i>	31	15	48,39	-18,19	-0,59
	KNN	8	6	75,00	16,75	2,09
	MLP	19	15	78,95	41,01	2,16

Nota: Para cada criptomoneda los mejores resultados se reportan en negrita. Los resultados iniciales del modelo heurístico están en cursiva.

Los resultados del período alcista (cuadro 4) muestran cómo la estrategia de aprendizaje automático puede lograr mejores resultados en las tres métricas analizadas. Además, los mejores algoritmos de clasificación son siempre KNN, SVC y MLP. Los dos primeros ya habían demostrado ser los mejores también en las simulaciones de inversión realizadas sobre

Cuadro 5.

Resultados operativos en el mercado bajista

<i>Moneda</i>	<i>Modelo</i>	<i>Inversiones</i>	<i>Inversiones rentables</i>	<i>Inversiones rentables %</i>	<i>Rendimiento total %</i>	<i>Rendimiento medio %</i>
BTC	<i>HE</i>	35	24	68,57	37,21	1,06
	KNN	66	30	45,45	10,02	0,15
	GNB	24	13	54,17	-10,27	-0,43
ETH	<i>HE</i>	43	26	60,47	48,22	1,12
	KNN	47	27	57,45	55,04	1,17
	LG	11	5	45,45	-4,17	-0,38
LTC	<i>HE</i>	36	21	58,33	39,41	1,99
	KNN	11	7	63,64	16,67	1,52
	SVC	12	9	75,00	23,67	1,97
XRP	<i>HE</i>	38	18	47,37	8,91	0,23
	GNB	20	11	55,00	23,43	1,17
	SVC	52	29	55,77	21,91	0,42

Nota: Para cada criptomoneda los mejores resultados se reportan en negrita. Los resultados iniciales del modelo heurístico están en cursiva.

el año 2020, superando siempre los resultados de la estrategia heurística y abriendo menos posiciones totales y más rentables. Al contrario, durante el mercado alcista, las simulaciones que emplea el clasificador abren más posiciones que la heurística, con la excepción de KNN, que logra alcanzar porcentajes de operaciones rentables y rendimientos medios muy elevados. SVC y MLP en cambio abren un mayor número de posiciones, aumentando enormemente los beneficios totales. En concreto, estas dos técnicas no obtienen buenos resultados de clasificación, sino altas ganancias cuando se aplican al mercado. Esto se debe a que clasifican erróneamente muchos días normales como días de reacción excesiva positiva, disminuyendo su puntuación de F1 y aumentando el número de señales largas. De esta manera, pueden aprovechar las numerosas subidas diarias que caracterizan el mercado alcista en el que operan, acumulando una alta ganancia total. En el período bajista (**cuadro 5**) la situación cambia ligeramente. La caída de los precios frena los rendimientos de todas las estrategias. KNN y SVC siguen siendo los mejores, aunque con resultados menos brillantes que en el período anterior. El número de posiciones abiertas también disminuye, lo que demuestra que la formación adicional en un período de alta volatilidad (2021) permite a los algoritmos de aprendizaje automático mejorar sus capacidades predictivas, como ya se ha mencionado anteriormente comentando los resultados de la clasificación.

5.2.3. Resultados de las simulaciones de inversión cruzada

Dado el alto dominio del mercado mostrado por bitcoin, se proponen más simulaciones de compraventa basadas en una estrategia cruzada. Específicamente, se utilizan predicciones generadas por clasificadores entrenados en datos de bitcoin para generar señales de mercado

para otras criptomonedas. Las simulaciones se limitan a los mejores clasificadores en términos de rentabilidad para bitcoin, es decir, KNN y SVC para el período alcista y KNN para el período bajista.

Cuadro 6.

Resultados operativos en el mercado alcista con predicción cruzada

Moneda	Modelo	Inversiones	Inversiones rentables	Inversiones rentables %	Rendimiento total %	Rendimiento medio %
ETH	<i>HE</i>	33	18	54,55	27,01	0,82
	MLP _{BTC}	9	7	77,78	31,92	3,55
	MNB _{BTC}	258	147	56,98	175,54	0,68
LTC	<i>HE</i>	33	19	57,58	0,73	0,02
	KNN _{BTC}	9	7	77,78	20,71	2,30
	SVC _{BTC}	258	137	53,10	83,89	0,33
XRP	<i>HE</i>	30	18	60,00	23,04	0,77
	KNN _{BTC}	9	6	66,67	6,67	1,85
	SVC _{BTC}	258	133	51,55	198,64	0,77
TRX	<i>HE</i>	34	16	47,06	4,08	0,12
	KNN _{BTC}	9	7	77,78	8,14	0,90
	SVC _{BTC}	258	134	51,94	137,12	0,53
XMR	<i>HE</i>	31	15	48,39	-18,19	-0,59
	KNN _{BTC}	9	7	77,78	26,70	2,97
	SVC _{BTC}	258	149	57,75	86,33	0,33

Nota: Para cada criptomoneda los mejores resultados se reportan en negrita. Los resultados iniciales del modelo heurístico están en cursiva.

Los cuadros 6 y 7 muestran los resultados obtenidos comparándolos con la estrategia heurística clásica utilizada en cada criptomoneda. En cuanto al mercado alcista, las predicciones realizadas sobre el bitcoin son efectivas para predecir movimientos de precios de otras criptomonedas. Esto demuestra una fuerte correlación de estas últimas con la principal y más antigua criptomoneda en el mercado. KNN_{BTC} se muestra nuevamente eficiente en reportar

Cuadro 7.

Resultados operativos en el mercado bajista con predicción cruzada

Moneda	Modelo	Inversiones	Inversiones rentables	Inversiones rentables %	Rendimiento total %	Rendimiento medio %
ETH	<i>HE</i>	43	26	60,47	48,22	1,12
	MNB _{BTC}	66	33	50,00	0,96	0,01
LTC	<i>HE</i>	36	21	58,33	39,41	1,09
	KNN _{BTC}	66	34	51,52	33,85	0,51
XRP	<i>HE</i>	38	18	47,37	8,91	0,23
	KNN _{BTC}	66	34	51,52	22,17	0,34

Nota: Para cada criptomoneda los mejores resultados se reportan en negrita. Los resultados iniciales del modelo heurístico están en cursiva.

operaciones rentables, obteniendo también altos rendimientos medios. SVC_{BTC} genera un gran número de señales a expensas de la precisión, permitiendo maximizar los beneficios. El mercado bajista vuelve a ser más difícil para las estrategias basadas en el aprendizaje automático, con el modelo heurístico obteniendo mejores resultados que KNN_{BTC} .

6. CONCLUSIONES

Después de presentar las principales características de la tecnología *blockchain*, este trabajo resume los pasos que llevaron al nacimiento y desarrollo de las criptomonedas y su mercado. Aunque esta versión moderna del dinero digital aporta varios beneficios de seguridad y no necesita una autoridad central, la alta volatilidad de los precios de estos nuevos activos todavía no permite utilizarlos como moneda alternativa a las modernas monedas fiduciarias. La alta frecuencia y la magnitud de las variaciones de precios también han atraído a un gran número de pequeños inversores, que sólo están interesados en las oportunidades de ingresos, lo que hace que el mercado sea extremadamente inestable. Algunos estudios también muestran que este mercado está sujeto a algunas de las anomalías estudiadas por las finanzas conductuales, incluido el efecto *momentum*. La segunda parte de este trabajo se centra precisamente sobre este último, ofreciendo una visión general de cómo se puede predecir el efecto *momentum* en el mercado de las criptomonedas, y cómo se puede aprovechar para generar beneficios mediante la realización de operaciones diarias. Después de presentar dos estrategias de inversión diferentes basadas en un modelo heurístico y otro de aprendizaje automático y los resultados obtenidos por ellos en una fase de mercado de movimiento lateral, se amplía el estudio a un período caracterizado por una alta volatilidad. Aunque la estrategia heurística presentada es rentable, muestra algunas limitaciones. El uso del aprendizaje automático permite aumentar la eficiencia de la estrategia de inversión, haciéndola más rentable, pudiendo procesar más información en forma de indicadores técnicos. Por lo tanto, el aprendizaje automático es una herramienta valiosa para usar en actividades de inversión, aunque tiene algunas desventajas. En primer lugar, la dificultad de predecir los precios reales obliga a utilizar modelos de clasificación, que solamente pueden utilizarse para predecir tendencias, generando así señales de inversión a corto plazo. Además, las tendencias analizadas son atribuibles a la psicología y al comportamiento de los inversores, ya que resulta complicado identificar el valor intrínseco de los activos. El mercado de las criptomonedas acentúa estas limitaciones al ser un mercado poco estructurado y muy volátil, poblado por inversores no institucionales que negocian con activos cuyo valor intrínseco a menudo es imposible de evaluar. Por esta razón, estas estrategias aún requieren un alto control, para poder interceptar grandes cambios o alteraciones del mercado, que podrían socavar su rentabilidad ya que los modelos están entrenados con datos históricos.

Referencias

- ATTANASIO, G., CAGLIERO, L. y BARALIS, E. (2020). Leveraging the explainability of associative classifiers to support quantitative stock trading. En *Proceedings of the Sixth International Workshop on Data Science for Macro-Modeling* (pp. 1-6).

- ATTANASIO, G., CAGLIERO, L., GARZA, P. y BARALIS, E. (2019). Quantitative crypto- currency trading: exploring the use of machine learning techniques. En *Proceedings of the 5th Workshop on Data Science for Macro-modeling with Financial and Economic Data- sets, DSMM@SIGMOD 2019, Amsterdam, The Netherlands, June 30, 2019*, 1:1-1:6. ACM. <https://doi.org/10.1145/3336499.3338003>
- BARIVIERA, A. F. (2017). The inefficiency of bitc oin revisited: A dynamic approach. *Economics Letters*, 161, pp. 1-4. ISSN: 0165-1765. (<https://doi.org/10.1016/j.econlet.2017.09.013>). (<https://www.sciencedirect.com/science/article/pii/S0165176517303804>).
- BARTOS, J. (2015). Does bitc oin follow the hypothesis of efficient market? *International Journal of Economic Sciences*, IV (enero), pp. 10-23. <https://doi.org/10.20472/ES.2015.4.2.002>
- BELLOCCA, G. P., ATTANASIO, G., CAGLIERO, L. y FIOR, J. (2022). Leveraging the momentum effect in machine learning-based cryptocurrency trading. *Machine Learning with Applications*, 8:100310. ISSN: 2666-8270. (<https://doi.org/10.1016/j.mlwa.2022.100310>). (<https://www.sciencedirect.com/science/article/pii/S2666827022000329>).
- BUSTOS, O. y POMARES-QUIMBAYA, A. (2020). Stock market movement forecast: A Systematic review. *Expert Syst. Appl*, 156, 113464. (<https://doi.org/10.1016/j.eswa.2020.113464>). (<https://doi.org/10.1016/j.eswa.2020.113464>).
- CAPORALE, G. M. y PLASTUN, A. (2020). Momentum effects in the cryptocurrency market after one-day abnormal returns. *Financial Markets and Portfolio Management*, 34, pp. 251-266.
- CHEVAPATRAKUL, T. y MASCIA, D. V. (2019). Detecting overreaction in the bitc oin market: A quantile autoregression approach. *Finance Research Letters*, 30 (septiembre), pp. 371-377. <https://doi.org/10.1016/j.frl.2018.11.004>
- CORBET, S., LUCEY, B. y YAROVAYA, L. (2018). Datestamping the bitc oin and Ethereum bubbles. *Finance Research Letters*, 26 (C): 81-88. <https://EconPapers.repec.org/RePEc:eee:finlet:v:26:y:2018:i:c:p:81-88>
- DERBENTSEV, V., BABENKO, V., KHRUSTALEV, K., OBRUCH, H. y KHRUSTALOVA, S. (2021). Comparative performance of machine learning ensemble algorithms for forecasting cryptocurrency prices. *International Journal of Engineering*, 34(1), pp. 140-148.
- GANDAL, N. y HALABURDA, H. (2014). Competition in the Cryptocurrency Market. *Working Papers*, 14-17. NET Institute. <https://EconPapers.repec.org/RePEc:net:wpaper:1417>
- GLENSKI, M., WENINGER, T. y VOLKOVA, S. (2019). *Improved Forecasting of Cryptocurrency Price using Social Signals*. arXiv: 1907.00558 [q-fin.ST].
- HUANG, B., HUAN, Y., XU, L. D., ZHENG, L. y ZOU, Z. (2019). Automated trading systems statistical and machine learning methods and hardware implementation: a survey. *Enterprise Information Systems*, 13(1), pp. 132-144. <https://doi.org/10.1080/17517575.2018.1493145>
- JEGADEESH, N. y TITMAN, S. (1993). Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency. *The Journal of Finance*, 48(1), pp. 65-91.
- KRAAIJEVELD, O. y DE SMEDT, J. (2020). The predictive power of public Twitter sentiment for forecasting cryptocurrency prices. *Journal of International Financial Markets, Institutions and Money*, 65, 101188. ISSN: 1042-4431. (<https://doi.org/10.1016/j.intfin.2020.101188>). (<https://www.sciencedirect.com/science/article/pii/S104244312030072X>).
- KURIHARA, Y. y FUKUSHIMA, A. (2017). The Market Efficiency of bitc oin: A Weekly Anomaly Perspective. *Journal of Applied Finance & Banking*, 7(3). https://EconPapers.repec.org/RePEc:spt:apfiba:v:7:y:2017:i:3:f:7_3_4
- LAHMIRI, S. y BEKIROS, S. D. (2021). Deep Learning Forecasting in Cryptocurrency High Frequency Trading. *Cogn. Comput.* 13(2), pp. 485-487. <https://doi.org/10.1007/s12559-021-09841-w>
- LANSDORP, S. y JELLEMA, W. (2013). Momentum from underreaction. *White Paper - ROBECO*.
- LIVIERIS, I. E., PINTELAS, E. G., STAVROYIANNIS, S. y PINTELAS, P. E. (2020). Ensemble Deep Learning Models for Forecasting Cryptocurrency Time-Series. *Algorithms*, 13(5), pp. 121. <https://doi.org/10.3390/a13050121>

- MURPHY, J. J. (1999). *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*. New York Institute of Finance Series. New York Institute of Finance. ISBN: 9780735200661. https://books.google.it/books?id=5zhXEqr%5C_IcC
- OZBAYOGLU, A. M., GUDELEK, M. U. y SEZER, O. B. (2020). Deep learning for financial applications: A survey. *Applied Soft Computing*, 93, 106384. ISSN: 1568-4946. <https://doi.org/10.1016/j.asoc.2020.106384>
- PLASTUN, A., BOURI, E., GUPTA, R. y JI, Q. (2021). Price effects after one-day abnormal returns in developed and emerging markets: ESG versus traditional indices. *The North American Journal of Economics and Finance*, 59 (octubre), 101572. <https://doi.org/10.1016/j.najef.2021.101572>
- ROUWENHORST, K. (1999). Local Return Factors and Turnover in Emerging Stock Markets. *The Journal of Finance*, 54(4), pp. 1439-1464.
- RUNDO, T., DI STALLO, A. L. y BATTIATO, S. (2019). Machine Learning for Quantitative Finance Applications: A Survey. *Applied Sciences*, 9, (24) (diciembre), 5574. ISSN: 2076-3417. (<https://doi.org/10.3390/app9245574>). (<http://dx.doi.org/10.3390/app9245574>).
- SUN, X., LIU, M. y SIMA, Z. (2020). A novel cryptocurrency price trend forecasting model based on LightGBM. *Finance Research Letters*, 32, 101084. ISSN: 1544-6123. (<https://doi.org/10.1016/j.frl.2018.12.032>). (<https://www.sciencedirect.com/science/article/pii/S1544612318307918>).
- URQUHART, A. (2016). The Inefficiency of bitcoin. *Economics Letters*, 148 (septiembre). <https://doi.org/10.1016/j.econlet.2016.09.019>

CAPÍTULO VII

Transacciones financieras y economía en tiempo real y alta definición: el consumo español

Alvaro Ortiz Vidal-Abarca*
Tomasía Rodrigo

Las transacciones financieras que ocurren de manera natural en la vida diaria constituyen una rica fuente de información para aproximar el comportamiento de una economía en tiempo real y en alta definición. La información anonimizada, procesada y agregada adecuadamente nos permite aproximar las cuentas nacionales tanto por el lado de la demanda, de la oferta y de las rentas a una frecuencia mucho más elevada a la oficial y con un grado de detalle muy superior al incluido normalmente en las encuestas. En este capítulo presentamos cómo utilizar los datos de transacciones financieras para el análisis del consumo español. El uso del *big data* nos ayuda a complementar a las estadísticas oficiales y abre una ventana de oportunidades en el diseño y ejecución de políticas inteligentes.

Palabras clave: *big data*, consumo, cuentas nacionales.

* Agradecemos los comentarios y sugerencias de Manuel Arellano, Scott Baker, V.V. Chari, Giancarlo Corsetti, Diane Coyle, Lukas Freund, Fatih Guvenen, Kyle Herkenhoff, Christopher Kurz, Francois Lafond, Rocio Madera, Clara Martínez Toledano, Mariacristina De Nardi, Fabrizio Perri, Christopher Rauh, Amir Sufi, Gianluca Violante, Michael E. Waugh y Nicolas Woloszko. También damos las gracias a los participantes en seminarios y conferencias del Banco de Canadá; el Banco de Italia; el CEPR Workshop on New Consumption Data; la OCDE; la 2022 European Micro-Macro-Midwest Conference; la Oficina de Estadísticas Nacionales del Reino Unido; el INE; el Banco de la Reserva Federal de Minneapolis; Banco de España; Riksbank-Federal Reserve Board-Bank of Canada-Bank of Italy Conference on Non-traditional Data, Machine Learning and Natural Language Processing in Macroeconomics; y US National Academies of Sciences, Engineering and Medicine's Panel on An Integrated System of U. S. Household Income, Wealth, and Consumption Data and Statistics to Inform Policy and Research. Agradecemos el apoyo y ayuda de Jose Miguel Leiva y Sirenia Vazquez en el proyecto y en general al equipo de BBVA Research por sus comentarios y sugerencias.

1. INTRODUCCIÓN

Desde hace décadas la inteligencia artificial ha venido desarrollándose de manera vertiginosa. La aceleración de esta tendencia no es casual, y es el resultado de la convergencia en el tiempo de avances paralelos en diferentes frentes. El primero de ellos, y quizás el más obvio, es el aumento de la capacidad de procesamiento de la información cuya velocidad es exponencial y vertiginosa. Esto ha reforzado un segundo avance, el rápido desarrollo de nuevos algoritmos y modelos que nos permiten día a día mejorar las reglas de decisión, acceder a nuevos datos y elaborar modelos para tratar fenómenos cada vez más complejos. Por último, y no menos importante, las dos han permitido un aumento rápido tanto de la digitalización de la información como de su procesamiento o conversión en información estructurada.

La cantidad de datos digitalizados ha aumentado a una velocidad asombrosa. Hoy en día, prácticamente el total de la información disponible en internet está digitalizado mientras que la capacidad de generar nueva información de los diferentes dispositivos aumenta segundo a segundo. Lo que entendemos por datos también está cambiando y un porcentaje creciente de la nueva información que se genera lo hace de manera no estructurada.

La Comisión Económica para Europa de las Naciones Unidas (UNECE) ha clasificado la información *big data* según sea de origen humano, generada por máquinas o procesada. Entre la información de origen humano destaca la información no estructurada en forma de textos, imágenes o vídeos (redes sociales, blogs, documentos personales, correo electrónico, mensajes de texto, búsquedas en internet, fotografías, audio y vídeo...) y que hoy en día podemos convertir en datos gracias a los avances en la capacidad de procesamiento y el desarrollo de los algoritmos de procesamiento de lenguaje natural (NLP), así como o algoritmos de redes neuronales utilizados para el tratamiento de imágenes y vídeos. El desarrollo de la tecnología y los numerosos dispositivos y sensores existentes en las calles o en las casas han permitido generar una ingente información proveniente de las máquinas. Por último, un tercer grupo de información es aquella registrada y procesada por empresas públicas y privadas. Entre las primeras, cabe destacar los datos generados por parte del sector público en forma de registros públicos. Entre los datos privados, una de las fuentes de información que se ha desarrollado más rápidamente, y principal objeto de análisis de este capítulo, son los datos agregados y anonimizados que provienen de las transacciones financieras.

El funcionamiento de los sistemas de pago modernos y de las instituciones financieras genera un registro completo de las transacciones diarias que se genera en tiempo real. Cada compra, cada débito, cada transferencia que realizamos deja una huella digital que termina registrándose como si de un gran libro de contabilidad se tratara. Esta gran cantidad de datos naturales y no estructurados sobre las transacciones, junto con los ricos metadatos asociados, está cada vez más al alcance de los investigadores y promete reconfigurar la medición económica. Cabe destacar que estos datos financieros, a diferencia de otros datos en tiempo real y alta definición, como los generados por la señal emitida a partir de terminales móviles o los generados de las aplicaciones de movilidad, nos permiten monitorizar actividad económica a través de movimientos financieros reales (como las compras) abarcando todos los sectores

de actividad, convirtiéndose así en una valiosa fuente de información para monitorizar la actividad.

Por diferentes motivos, esto no ha pasado desapercibido para la academia, las agencias nacionales de estadística y los responsables de la política económica, que vienen reafirmando desde hace unos años que los datos de transacciones financieras desempeñarán un papel cada vez más importante en la contabilidad nacional del siglo XXI (véase, por ejemplo, Lewis, 2020 y Ehrlich *et al.*, 2022).

En este capítulo mostramos cómo podemos utilizar los datos de transacciones financieras para replicar las cuentas nacionales. Nos centraremos en el caso del consumo de los hogares dada su relevancia (55 % del PIB). Además, mostraremos cómo podemos utilizar esta información para el desarrollo de indicadores de actividad en tiempo real y, dada su elevada granularidad, en alta definición.

En el primer apartado describimos brevemente la literatura reciente sobre el uso de los datos de transacciones financieras en tiempo real. Nos centraremos en la descripción de las diferentes datos financieros que han sido utilizados por los trabajos recientes, así como las ventajas e inconvenientes de utilizar este tipo de información frente al uso de los indicadores tradicionalmente utilizados por las agencias estadísticas.

En un segundo apartado describimos cómo podemos utilizar los datos financieros de pagos de los individuos a las empresas para replicar el consumo. Aparte de detallar los diferentes medios de pago, realizamos una descripción del proceso de limpieza y procesamiento de los datos para alcanzar una medición completa del consumo, en lugar de analizar solamente los datos de tarjetas de crédito y de débito como la mayoría de los trabajos existentes.

Aunque una de las propiedades más destacadas de este tipo de transacciones es la posibilidad de registrar la actividad económica en tiempo real, no menos importante es el componente de alta definición que presentan los datos de transacciones. En el tercer apartado mostramos cómo la alta granularidad de estos datos se está traduciendo en un aumento notable de las posibilidades que ofrece para el análisis económico, sobre todo en el desarrollo de cuentas distributivas del consumo e ingresos.

La alta definición de los datos, abre la puerta al uso de indicadores *big data* para el desarrollo de políticas económicas inteligentes. La alta granularidad de las transacciones supone una ventaja notable para los *policy-makers* a la hora de desarrollar políticas inteligentes. El hecho de que podamos acceder a la información de los individuos y empresas en alta definición permite enfocar y dirigir las políticas económicas allá donde más se necesitan o donde pueden lograr un mayor impacto en términos de bienestar.

Por último, y a modo de conclusión, introducimos un conjunto de reflexiones analizando las ventajas de la información proveniente de las transacciones financieras, aventurándonos a señalar algunos de los aspectos que vayan a tener más importancia en los próximos años.

2. TRANSACCIONES FINANCIERAS EN TIEMPO REAL: LITERATURA RECIENTE

La medición detallada del ciclo económico y sus componentes (consumo privado, inversión) ha constituido desde hace décadas un ingrediente clave en diferentes campos tanto de análisis como de política económica. Para ello, los economistas hemos utilizado tradicionalmente la información elaborada por organismos nacionales de estadística, diferentes ministerios o bancos centrales en forma de indicadores de diversa índole (PIB, consumo, producción industrial, desempleo, etc.) para evaluar el estado del ciclo económico. En términos generales, esta información tiene como base la información que proviene de encuestas a una muestra representativa de individuos o empresas sobre cuestiones de diferente índole (decisiones de compra, decisiones de inversión, . . .).

La información que proviene de las encuestas tiene ventajas y desventajas. Entre las ventajas, las encuestas están diseñadas para ser consistentes con el sistema de cuentas nacionales y ser representativas de la población. No obstante, también existen inconvenientes como la baja frecuencia de los datos, el número limitado de los encuestados, los retrasos en la publicación de estadísticas clave como el PIB, la baja granularidad de la información en algunos casos y las frecuentes revisiones de la información. Además, existen problemas de carácter logístico como los elevados costes y la cada vez menor participación en las encuestas.

Recientemente los investigadores y analistas han recurrido a los datos de las transacciones financieras para complementar la información tradicional. A pesar de que se les etiqueta también como “No tradicionales”, la información de las transacciones financieras lleva con nosotros mucho tiempo. La relación entre las transacciones financieras y la actividad económica tampoco es nueva y forma parte ya de trabajos seminales de grandes autores como Keynes, Fisher y muchos otros. No ha sido, por tanto, extraño que estos datos que “ocurren naturalmente” (Bean, 2016) comenzaran a explotarse masivamente a medida que la capacidad de proceso de los computadores y el desarrollo de nuevos algoritmos lo fueran permitiendo.

Pero la información que proviene de las transacciones financieras tiene también ventajas y desventajas. Entre las ventajas podemos destacar las siguientes:

- Al provenir de registros, y no de encuestas, la información puede ser igual de precisa si la información es suficientemente representativa y está debidamente procesada.
- El número de registros supera con creces normalmente al de los encuestados y la información posee un elevado grado de granularidad o alta definición.
- La información se procesa casi en tiempo real y suele ser de carácter diario. Esto supone una ventaja notable para los responsables de política económica, pues su respuesta a las condiciones económicas puede ser mucho más inmediata. De hecho, la necesidad de reaccionar rápidamente a las cambiantes condiciones económicas tras la crisis del COVID-19 ha potenciado, sin duda, el uso de los datos de transacciones financieras en la evaluación del estado de la actividad económica.

- Las transacciones están geolocalizadas, por lo que el potencial para el análisis a nivel desagregado es muy elevado.
- Por último, el coste de este tipo de información es mucho más bajo para las oficinas estadísticas. Esto es especialmente relevante para el desarrollo de estadísticas en los países en vías de desarrollo.

Sin embargo, también existen inconvenientes a la hora de utilizar este tipo de información para el seguimiento de la actividad económica:

- Aunque numerosos, los datos no recogen una muestra de la población sino de los clientes de la entidad financiera. Esto es muy relevante, pues la existencia de sesgos puede limitar la precisión de la información al evaluar el ciclo económico.
- En la mayoría de los casos, las bases de datos de transacciones de las instituciones financieras no fueron diseñadas para el análisis económico o para ser consistentes con las cuentas nacionales. Existen, por ejemplo, transacciones con tarjetas de crédito que no constituyen un gasto de consumo privado (pago de impuestos o compra de bitcoins con tarjetas, por ejemplo) o bien corresponden a una exportación de bienes y servicios (como el gasto con tarjetas de un no residente en España). Tener acceso a los datos brutos de transacciones financieras no garantiza que vayan a poder ser utilizados inmediatamente para el análisis. En términos generales hay un trabajo exhaustivo de procesamiento del dato antes de poder utilizarlo para el análisis.
- El tratamiento de los datos financieros tiene que cumplir en todo momento con la regulación y preservar la privacidad de los individuos.
- El coste de procesamiento del dato para las entidades que proporcionan los datos es normalmente elevado.

Aunque el procesamiento de estos datos no es sencillo y no está exento de costes, las numerosas ventajas en su utilización han llevado a analistas e investigadores a trabajar y mejorar continuamente su calidad. En este sentido, es clave que analistas e instituciones privadas y públicas continúen trabajando para garantizar la consistencia de esta información con las estadísticas oficiales. El desarrollo de un procesamiento de los datos consistente con los principios clave de las estadísticas oficiales (representatividad, estabilidad, consistencia...) es clave para el futuro de esta información como herramienta de análisis económico. Sólo así se puede garantizar la robustez y la confianza en este tipo de información para poder complementar con éxito a las fuentes de información tradicionales provista por los organismos oficiales.

Aunque en términos generales nos referimos a estos datos como transacciones financieras, su naturaleza y su utilización puede ser muy distinta. Baker y Kueng (2022) resumen bien la evolución en el uso de los datos de transacciones financieras que se ha producido en los últimos años en tres grandes grupos:

- Una primera oleada de trabajos comenzó a explotar los datos de las cuentas de los intermediarios bursátiles o *brokers*. A partir de ellos, algunos investigadores comenzaron a explorar y entender mejor como los inversores tomaban sus decisiones. A través de sus análisis encontraron diferencias por género o como los inversores cometían errores sistemáticos que penalizaban la tasa de retorno de las inversiones.
- A partir de principios de la década de 2010, comienzan a surgir trabajos que explotan datos detallados de las transacciones de las cuentas bancarias. Estos datos son suministrados bien por entidades bancarias individuales, bancos *online* o asociaciones de bancos. Dado que los bancos ofrecen una amplia gama de servicios a los clientes (cuentas corrientes, tarjetas de débito y crédito, hipotecas, préstamos al consumo...), estos datos ofrecen la posibilidad de observar no sólo los flujos completos de gastos e ingresos, sino también varios tipos de activos, el comportamiento de los préstamos y otra información demográfica. Como veremos más tarde, algunos de estos datos como los de transacciones de tarjetas resultaron ser muy relevantes en 2020 durante la epidemia del COVID-19 y los confinamientos.
- Una opción más limitada ha sido obtener acceso a los datos de las transacciones directamente de las empresas de tarjetas de crédito (véase, por ejemplo, Einav y Klenow, 2021) o de los emisores de tarjetas de crédito (por ejemplo, Gathergood *et al.*, 2021). El aumento de las aplicaciones de pago, como Apple Pay, Venmo y AliPay, ha creado nuevas vías para observar directamente las transacciones de gasto de los hogares en grandes sectores de la población de muchos países.
- Los análisis de la ciencia del comportamiento (*Behavioural Economics*) se han visto beneficiados del trabajo pionero de un ecosistema emergente de productos y aplicaciones *fintech*. Entre los datos que proveen estas *startups* se encuentran los que agregan y hacen un seguimiento de las distintas cuentas financieras de un cliente, y los que se centran más en un objetivo final concreto, como aumentar las tasas de ahorro o ayudar a pagar las deudas.

Pero sin duda alguna, la mejor demostración de las ventajas de estos datos ha sido su uso durante la crisis sanitaria generada por el COVID-19 que arrasó la economía mundial durante el primer trimestre de 2020. La pandemia y los confinamientos que se implementaron en muchos países para combatirla generaron una crisis económica sin precedentes. La crisis provocó una recesión súbita, sin precedentes en términos de magnitud y velocidad de propagación. Dada la incertidumbre del evento, los datos tradicionales que habían sido utilizados en anteriores ocasiones no logran proporcionar una visión rápida y certera de lo que estaba ocurriendo.

La rapidez con la que se produjo la crisis durante los días del final de primer y principios del segundo trimestre de 2020 generó una elevada incertidumbre sobre la magnitud de la crisis y las políticas que se debían implementar para combatirla. En este sentido, la lentitud y desfase con la que se publican los indicadores económicos tradicionales no ayudaban a la toma de decisiones. Ante ello, muchos investigadores comenzaron a hacer uso de los

datos de transacciones financieras para analizar en tiempo real lo que estaba ocurriendo en la economía.

La mayoría de estos trabajos se centraron en los datos de transacciones de tarjetas para elaborar un seguimiento en tiempo real de la magnitud de la crisis. La respuesta fue relativamente rápida y algunos documentos de trabajo se publicaron solo un par de meses después del estallido del COVID-19. La mayoría de estos trabajos se enfocaron en países desarrollados como Andersen *et al.* (2020a) para Dinamarca y Suecia; Chetty *et al.* (2020) y Cox *et al.* (2020) para los Estados Unidos; Chen *et al.* (2021) para China; Carvalho *et al.* (2021) y Aspachs (2021) para España; Chronopoulos, Lukas, Wilson (2020) y Hacioglu, Kanzig, Surico (2020) para el Reino Unido, y Bounie, Camara, Galbraith (2020) en el caso de Francia. Sólo un par de estudios han extendido este trabajo empírico a las economías emergentes, como el caso de Carvalho *et al.* (2021) que utilizó información de tarjetas de crédito y débito como *proxy* del consumo en Turquía, México, Colombia, Perú y Argentina, o Chen (2021) que utilizó datos de consumo *online* para China.

En nuestro caso (Carvalho *et al.*, 2021) pronto comenzamos a descubrir algunas de las características de la crisis y de los efectos de los confinamientos en el consumo en los diferentes países analizados: una caída sin precedentes del consumo media del 40-45 % consecuencia de los confinamientos, con una elevada propagación en los distintos países, con mayor intensidad en aquellos sectores sujetos a las restricciones (como por ejemplo servicios), con un mayor efecto relativo en los segmentos de renta más elevados pero que, afortunadamente, fueron seguidos de una recuperación también sin precedentes.

3. RE-CONSTRUYENDO EL CONSUMO A TRAVÉS DE LOS MEDIOS DE PAGO

Para la construcción de nuestros indicadores de consumo en tiempo real y alta definición nos basamos en el universo de operaciones financieras realizadas por clientes particulares de BBVA en España en el periodo 2015T2 a 2021T4. A diferencia de otros trabajos previos, como destacamos previamente, vamos más allá del uso de datos de transacciones de tarjetas de crédito y débito y consideramos todos los medios de pago a través de los cuales los individuos pueden consumir, capturando de forma más precisa la dinámica del consumo total y entendiendo la evolución desigual de cada componente. Concretamente, medimos el consumo realizado con tarjeta de crédito y débito en puntos de venta (TPV) físicos y virtuales (comercio electrónico), que suponen un 26,5 % y un 8,5 % del consumo total respectivamente; el consumo realizado a través de domiciliaciones bancarias, comúnmente utilizadas para el pago de suministros del hogar como agua, electricidad, gas y comunicaciones (teléfono, red wifi, televisión a la carta, etc.), con un peso del 20 % del consumo total; el consumo a través de transferencias monetarias, ligado sobre todo a la compra de bienes duraderos como vehículos (5 % del consumo total); el pago de alquileres, que se trata del mayor componente del consumo (cercano al 25 % del total); y finalmente el efectivo, aproximado a través de las retiradas de efectivo en los cajeros BBVA y ventanilla, que representa el 15 % del total.

Los indicadores contruidos a partir de estos datos siguen los principios de contabilidad nacional para replicar las estadísticas oficiales del consumo agregado en las cuentas nacionales elaboradas por el INE. Para ello es importante entender los métodos utilizados por el INE, que están avalados y en línea con el sistema de cuentas nacionales de Eurostat. La información base en el caso del INE proviene de la *Encuesta de Presupuestos Familiares (EPF)*, que mide el consumo individual y de los hogares en los distintos grupos demográficos y tipos de productos y servicios. En esta encuesta, se define un conjunto de 2.275 secciones censales en función del tamaño del municipio, el empleo, la edad, la educación y otras características socioeconómicas. Dentro de estas secciones, se seleccionan aleatoriamente diez viviendas para participar en la encuesta durante dos años, con una rotación escalonada en la que la mitad de la muestra se sustituye cada año. Los hogares registran sus gastos durante un periodo de dos semanas donde a cada compra se le asigna una clasificación basada en el sistema de cinco dígitos de la clasificación individual de consumo por finalidad (*COICOP*, por sus siglas en inglés: *Classification of Individual Consumption by Purpose*). Los pagos recurrentes se estiman por el importe de la última factura emitida. En el caso de los hogares que son propietarios de sus viviendas, el INE imputa el valor de consumo de los servicios de la vivienda utilizando información sobre el tamaño de la casa y los precios locales de alquiler, además de las estimaciones subjetivas de los encuestados.

Para convertir los datos de gasto de BBVA en una encuesta de consumo hay dos temas esenciales a tratar. El primero es la definición de la muestra: tenemos que asegurar que el conjunto de clientes de BBVA es representativo de la población nacional. El segundo es que no todo el gasto de los consumidores equivale al consumo. El gasto en productos fuera del sistema de clasificación *COICOP* no se considera consumo en cuentas nacionales. Sin embargo, los datos de gasto del banco no siguen esta clasificación para limpiar las observaciones no asociadas a consumo, por lo que es necesario hacer una asignación de dicho gasto a *COICOP* para desestimar todo lo que no se considera consumo. Otro aspecto relevante al que le tenemos que prestar atención es a la estimación de los servicios de vivienda, que son una parte importante del consumo total (25 %), pero no se observan directamente en los datos de gasto de quienes son propietarios y ocupan sus viviendas.

3.1. De clientes BBVA a población representativa

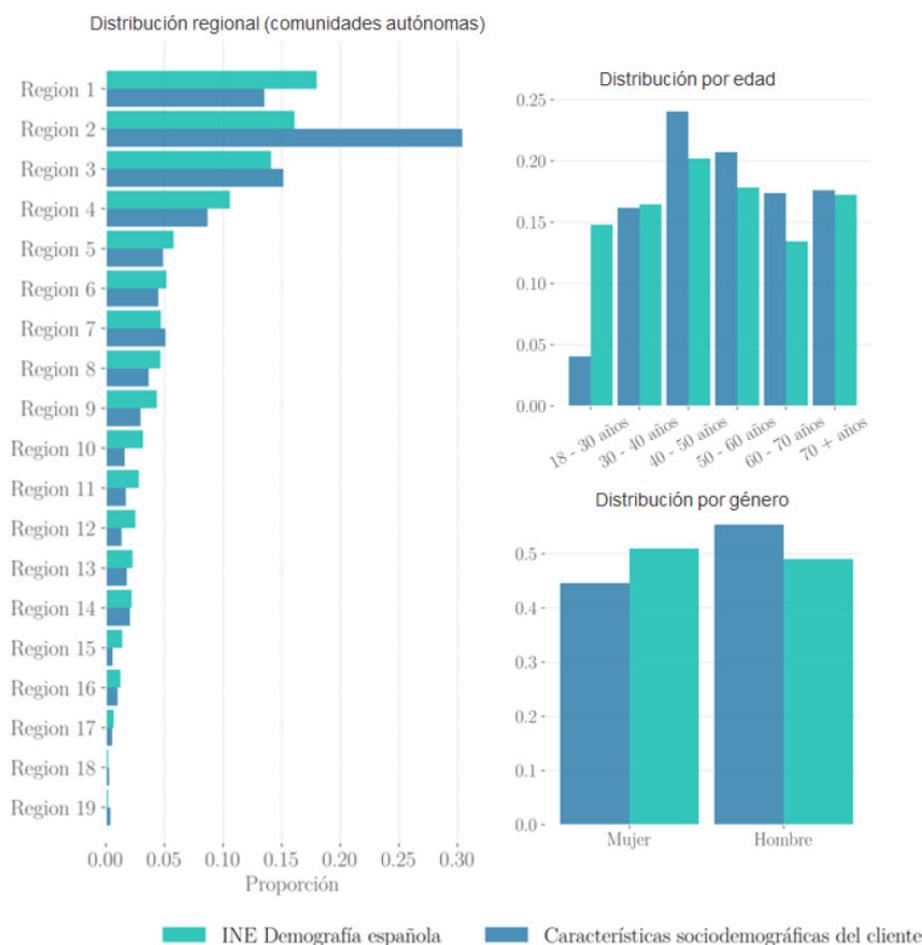
El conjunto de clientes particulares de BBVA que realizan al menos una transacción relacionada con el consumo entre 2015 T2 y 2021 T4 es de 10.270.041, lo que supone un 26 % del total de la población adulta España en 2021, que asciende a 39.177.710. Muchos de estos clientes gastan con poca frecuencia a través de nuestro sistema bancario. Para asegurar una vinculación de los clientes que nos permita seguir mejor su trazabilidad, definimos un panel de clientes activos que realizan al menos diez transacciones relacionadas con consumo en cada trimestre. De esta forma, nos quedamos con 1.827.866, excluyendo autónomos cuyas transacciones podrían reflejar insumos de producción en lugar de consumo. Además, este panel de clientes activos durante todo el periodo de estudio nos asegura que cualquier creci-

miento observado en el gasto agregado está impulsado por el aumento del gasto de nuestros clientes y no por un aumento de la cuota de mercado de BBVA.

Sobre este conjunto de clientes activos, estudiamos la distribución de su ubicación geográfica, de su residencia, edad, sexo e ingresos del distrito, comparándolos con los de todos los españoles registrados en el censo (figura 1). Para cada cliente de BBVA se observan datos de edad, género y domicilio. Los gráficos de barras comparan la distribución de las características de los clientes activos con los datos del censo español en 2018. Para construir la distribución de la renta del distrito, utilizamos la información que proporciona el INE sobre la renta

Figura 1.

Distribución sociodemográfica de los clientes activos



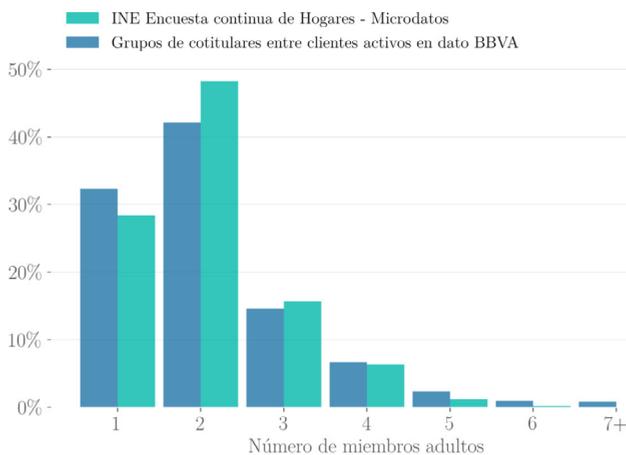
media de los residentes de cada sección censal en España (36.581 en total)¹. Sobre la base de la renta media, agrupamos las secciones censales en quintiles dentro de cada una de las 52 provincias españolas y trazamos la distribución de la población española en cada quintil. A continuación, asignamos los clientes activos a las secciones censales en función del código postal y trazamos la distribución entre los quintiles.

En general las distribuciones están claramente relacionadas, pero existen discrepancias relevantes a solventar: por ejemplo, los clientes activos de BBVA están sobrerrepresentados en una región concreta, entre los hombres y entre las personas de mediana edad. También es más probable que vivan en distritos con mayores ingresos. Es por ello, que necesitamos convertir esta muestra en representativa reponderando el consumo de cada grupo como explicamos en el apartado 3.2.3.

La estructura familiar de los clientes activos es importante para determinar su consumo, pero no se observa directamente en los datos. Es por ello que la inferimos vinculando a cada cliente activo con el conjunto de otros clientes BBVA (estas relaciones se establecen sobre información tokenizada, sin poder identificar la identidad del cliente) que hayan firmado conjuntamente un contrato financiero (por ejemplo, que sean cotitulares de una cuenta bancaria, responsables conjuntos de un préstamo, etc.) en cualquier momento de la muestra y que residan en el mismo código postal al final de la muestra. Esto crea una estimación inicial del número de personas en el hogar de cada cliente activo además de él mismo. En estos casos, se unen los clientes en un solo hogar generando 1.589.280 grupos de hogares.

Figura 2.

Tamaño del hogar: dato BBVA vs. dato oficial



¹ Esta información existe para todas las comunidades autónomas excepto para el País Vasco y Navarra. Ceuta y Melilla son pequeños enclaves que no están subdivididos en secciones censales.

En los casos en los que un cliente activo no está emparejado con ningún otro cliente de BBVA, pero figura como casado, suponemos que reside con otra persona, por ejemplo, un cónyuge. Por último, BBVA registra para cada cliente el número de adultos dependientes en el hogar. Si después de los pasos anteriores un cliente activo se agrupa con menos personas de las que aparecen como adultos dependientes, registramos el número de miembros adicionales del hogar igual al número de adultos dependientes. La *figura 2* compara la distribución resultante del tamaño de los hogares según nuestro procedimiento de agrupación con los datos oficiales. En general encontramos bastantes similitudes entre ambos grupos.

En resumen, contamos con una muestra de 1.827.866 clientes activos que forman 1.589.280 hogares, cuyo gasto en consumo observamos entre 2015 y 2021. En el caso de la *Encuesta de Presupuestos Familiares* del INE, contaron con 40.285 adultos y 19.170 hogares. De esta forma, nuestros datos incrementan significativamente el número de individuos cuyo consumo se puede registrar, lo que a su vez permite un corte mucho más fino de los datos. Además, a diferencia de nuestros datos, no se puede hacer un seguimiento del gasto a lo largo del tiempo de los individuos con los datos oficiales, dado que ningún hogar participa en la *EPF* durante más de dos años.

3.2. Del gasto al consumo

El siguiente reto es convertir los datos de gasto individual en datos de consumo. Para el consumo no relacionado con la vivienda, utilizamos los datos de transacciones para clasificar las compras individuales en dos grupos, las relacionadas con el consumo y los que no lo están. En el caso de que correspondan a datos de consumo, les asignamos una categoría de consumo de acuerdo a la clasificación *COICOP*. Por otro lado, para el consumo de vivienda, estimamos un modelo de regresión simple que predice los pagos de alquiler observados de las características de los hogares con objeto de imputar los pagos mensuales de vivienda de todos los clientes activos.

3.2.1. Consumo no relacionado con la vivienda

De acuerdo a la definición de gasto en consumo final de cuentas nacionales, eliminamos las transacciones bancarias que no se ajustan a esta definición como por ejemplo las transferencias a instituciones de inversión o los pagos de impuestos y clasificamos cada transacción en categorías de consumo de acuerdo a la clasificación *COICOP* a nivel de dos dígitos (*cuadro 1*).

Hay tres modos de transacción distintos en los datos –gastos con tarjeta, adeudos en cuenta y transferencias bancarias no periódicas– y cada uno tiene una estructura distinta para categorizarlos. En el caso de las tarjetas nos basamos en el código de cliente comercial (MCC)

Cuadro 1.

Categorías de consumo COICOP (dos dígitos)

<i>Categoría</i>	<i>Descripción</i>
01	Alimentos y bebidas no alcohólicas
02	Bebidas alcohólicas, tabaco y narcóticos
03	Ropa y calzado
04	Vivienda, agua, electricidad, gas y otros combustibles
05	Mobiliario, equipamiento doméstico y mantenimiento rutinario del hogar
06	Salud
07	Transporte
08	Comunicaciones
09	Ocio y cultura
10	Educación
11	Restaurantes y hoteles
12	Bienes y servicios diversos

o identificador del comercio, que es un sistema estandarizado para clasificar las actividades comerciales. Hay un total de 835 MCC, lo que permite desagregar con precisión las categorías de gasto y asignarlas a una categoría *COICOP*, con dos excepciones. En primer lugar, hay MCC que se refieren al consumo genérico. El ejemplo más destacado es la retirada de efectivo en cajeros automáticos. En segundo lugar, un número limitado de MCC se refiere a las ventas de minoristas multiproducto, como los supermercados. En estos casos, utilizamos las estadísticas publicadas sobre la distribución de las ventas en las categorías *COICOP* por sectores para imputar el gasto en estos establecimientos.

Para las operaciones de adeudo en cuenta, principalmente pago de facturas de suministros de energía, telecomunicaciones, seguros... , utilizamos la misma aproximación. Nos basamos en la empresa que recibe el pago para asignarla a una categoría *COICOP* a través de su identificación fiscal o código CNAE. Las transferencias ordinarias son el medio de pago más complicado de clasificar. Si identificamos a la contrapartida como una empresa, clasificamos las transferencias utilizando, como en el caso de adeudos, la información fiscal y pública de la empresa. El **cuadro 2** presenta el número y el volumen de las transacciones realizadas por

Cuadro 2.

Volumen de datos de consumo de clientes activos (todo el período)

<i>Categoría de gasto</i>	<i>Volumen de transacciones</i>	<i>Número de transacciones</i>
Transacciones presenciales con tarjeta	60.319 millones de euros	1.772 millones
Transacciones <i>online</i> con tarjeta	11.858 millones de euros	313 millones
Adeudos en cuenta	66.036 millones de euros	752 millones
Retiradas de efectivo	64.592 millones de euros	359 millones
Transferencias excl. renta	11.148 millones de euros	15 millones

los clientes activos de nuestra muestra que clasificamos como relacionadas con el consumo, desglosadas por tipo de transacción.

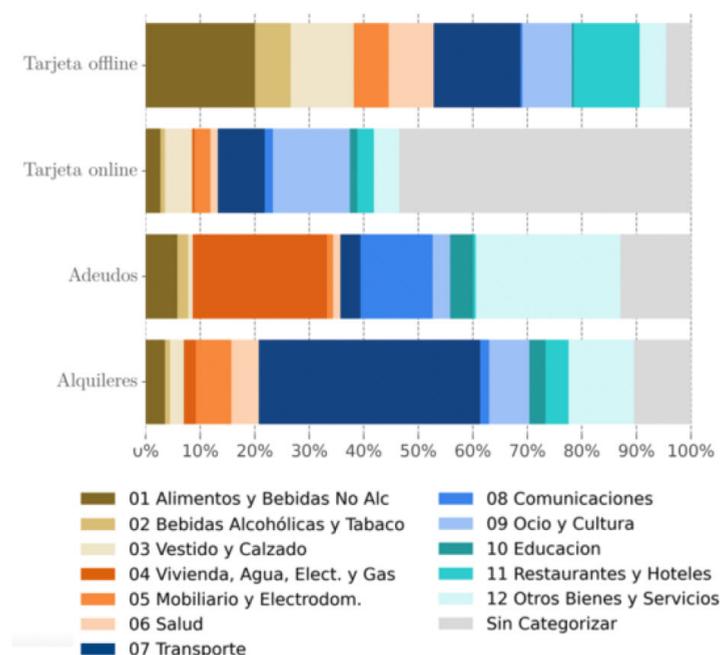
El valor total del gasto es de aproximadamente 200.000 millones de euros, que engloban 3.000 millones de transacciones totales. Aunque las transacciones con tarjeta constituyen la gran mayoría del total de transacciones, su valor total es comparable al de los adeudos en cuenta.

La **figura 3** muestra la distribución de las categorías de consumo según el medio de pago. Se observa una importante heterogeneidad entre ellos. El gasto en alimentación constituye una parte sustancial del gasto con tarjeta presencial. El transporte representa casi la mitad de las transferencias no periódicas, mientras que los pagos de suministros se realizan principalmente mediante adeudos en cuenta.

Por último, excluimos de la muestra a los clientes activos cuyo consumo no relacionado con la vivienda es elevado en relación con los ingresos medios de su sección censal, eliminando así valores atípicos de la distribución.

Figura 3.

Distribución del consumo por COICOP por medio de pago



3.2.2. Consumo relacionado con la vivienda

Para la medición del consumo en vivienda, el primer paso es identificar todos los pagos de alquiler utilizando los términos "alquiler" o "renta" en castellano y otros idiomas regionales. Excluimos las transacciones que incluyen además términos que indican que el pago del alquiler es para un bien que no es la vivienda, como un garaje, una plaza de aparcamiento o un coche. También imponemos un valor mínimo de 100 euros para que una transacción se considere alquiler.

La unidad natural de análisis del consumo relativa a la vivienda es el hogar, por lo que buscamos los pagos realizados por todos los individuos que componen los hogares, sean o no clientes activos. A continuación, sumamos todos los pagos de alquiler a nivel de hogar y mes, obteniendo 437.307 hogares que tienen al menos un pago de alquiler. Para evitar el ruido derivado de los hogares con pocas observaciones mensuales de alquiler, nos centramos en los hogares con pagos de alquiler no ausentes en, al menos, 70 de los 81 meses totales de nuestra muestra, quedándonos con 32.127 hogares.

Para el modelo de estimación del alquiler, utilizamos los ingresos (que representan indirectamente la calidad de la vivienda), los pagos de suministros (que representan indirectamente el tamaño de la vivienda) y la ubicación geográfica. Para los ingresos nos basamos en los datos BBVA sobre los ingresos mensuales procedentes de los salarios, las prestaciones públicas y las pensiones, y calculamos los ingresos medios semestrales de los hogares. Los pagos de suministros se calculan a partir de la tabla de adeudos en cuenta. Solamente mantenemos en la muestra de estimación los hogares que tienen al menos un mes de pagos de suministros e ingresos observados. Esto reduce el número de hogares objeto de estudio a 16.977.

Para la localización geográfica, buscamos definir unidades geográficas que estén lo suficientemente pobladas de hogares como para poder estimar los efectos fijos de forma fiable. Por último, realizamos una regresión de los pagos mensuales de alquiler por hogar sobre los efectos fijos de la unidad geográfica, los ingresos y los pagos de suministros mediante mínimos cuadrados ordinarios. Cuando no se dispone de información sobre los ingresos o los suministros para elaborar el registro de un mes determinado, utilizamos la media del hogar en todos los meses.

El **cuadro 3** muestra los resultados. Aunque es sencillo, el modelo explica el 40 % de la variación de los pagos de alquiler, y ambas covariables continuas son altamente significativas y contribuyen a un elevado R^2 dentro de la región. Los coeficientes estimados implican que un cambio de una desviación estándar en los ingresos desplaza los pagos de alquiler en 70 euros al mes, es decir, un 0,28 del IQR de la distribución general de los pagos de alquiler. El impacto de los suministros es más moderado, con un cambio de una desviación estándar que desplaza el alquiler en sólo 21 euros.

A continuación, utilizamos nuestra regresión de alquileres estimada para imputar los alquileres mensuales a todos los hogares. Cuando un hogar se encuentra fuera de las unidades

Cuadro 3.

Regresión modelo de alquiler

<i>Variable</i>	<i>Modelo</i>	<i>Conjunto en estudio</i>
Gasto en suministros al hogar	0,0884 (0,0008)	
Ingresos	0,0362 (0,0011)	
Número de hogares	16.977	15.512
Número de observaciones	1.134.735	15.512
R ²	0,3911	
R ² ajustado	0,3765	
Dentro de R ²	0,1200	
MSE raíz	204.614,4	221,64

geográficas definidas para la muestra de estimación, lo asignamos a la unidad más cercana basándonos en la distancia del centroide. Cuando no se dispone de información sobre los ingresos o suministros para elaborar el registro de un mes determinado, utilizamos la media del hogar en todos los meses. Si un hogar no tiene registros de suministros o ingresos, imputamos la media de la unidad geográfica.

Para elaborar una primera estimación de la precisión fuera de la muestra, consideramos los 15.512 hogares para los que observamos entre 50 y 70 pagos mensuales de alquiler y calculamos el error cuadrático medio del alquiler imputado con respecto al alquiler real para un mes elegido al azar para cada hogar. El error cuadrático medio sólo aumenta ligeramente en comparación con la muestra de estimación, lo que sugiere que nuestro modelo de alquiler, aunque sencillo, se generaliza bien fuera de la muestra. Los promedios también se ajustan bien: el alquiler medio real es de 551 euros y el alquiler medio imputado es de 538 euros.

3.2.3. Ponderación de hogares y demográfica

El proceso descrito da lugar a una medida de consumo no relacionado con la vivienda c_i^{NH} para cada cliente activo i , y a una medida de consumo de servicios de vivienda definida a nivel del hogar h . El último paso para producir medidas de consumo agregadas es ajustar estos totales en función de la vivienda y la estructura demográfica. Es importante tener en cuenta la estructura de los hogares porque una parte del gasto de cada cliente activo se realiza potencialmente en nombre de otros. Por otro lado, como no tabulamos el gasto de los clientes no activos (excepto en vivienda), estamos perdiendo la parte de su gasto que beneficia a clientes activos. Para equilibrar estos efectos, adoptamos el siguiente esquema de ponderación. $A(i)(O(i))$ es el conjunto de clientes activos (otros) del hogar de i . Así, el consumo ponderado del hogar es:

$$c_i = \frac{\sum_{j \in A(i)} c_i^{NH} + c_{h(i)}^H}{|A(i)| + 0,5|O(i)|}$$

Supongamos primero que un hogar está formado sólo por clientes activos. En ese caso, la fórmula anterior agrega el gasto de todos los miembros y lo divide en partes iguales. Si el hogar también contiene miembros no activos, aplicamos una ponderación adicional a la baja que trata a cada cliente no activo como 0,5 de un cliente activo. Los clientes no activos comparten el consumo de los clientes activos, pero también generan potencialmente gasto de consumo fuera del universo BBVA. La ponderación a la baja de $0,5|O(i)|$ tiene en cuenta estas fuerzas contrapuestas.

De esta forma, agregamos el gasto individual a nivel de género (g), grupo de edad (a) y quintil de ingresos del distrito (q). Dado que los quintiles de distrito se forman por separado para cada región, esta última variable garantiza también la representatividad regional. Así, se define $c_{t;g,a,q}$ como la suma de acuerdo a la fórmula anterior de todos los clientes activos en la celda (g, a, q) calculada en el momento t . Dependiendo del contexto, t puede ser anual, trimestral, mensual, etc. Para agregar entre celdas en cada periodo de tiempo t , tenemos en cuenta los desequilibrios demográficos entre la muestra de clientes activos y los datos censales españoles de 2018. Se define $x_{g,a,q}^{INE}$ como el recuento total de adultos españoles según los datos censales en la celda (g, a, q) en 2018. Asimismo, se define $x_{\tau(t);g,a,q}^{BBVA}$ como el recuento total de clientes activos en la celda (g, a, q) en el año τ que depende del periodo de interés t . El consumo total en cada celda en el momento t es:

$$c_{t;g,a,q}^W = c_{t;g,a,q} \times \left(\frac{x_{g,a,q}^{INE}}{x_{\tau(t);g,a,q}^{BBVA}} \right)$$

El consumo agregado es la suma de todas las celdas, mientras el consumo del cuartil regional del distrito (q) es la suma de todas las categorías de género y edad manteniendo (q) fija, y así sucesivamente. El consumo específico de cada categoría se obtiene considerando únicamente el subconjunto de $c_{t;g,a,q}$ que pertenece a la categoría COICOP de interés. Con esta ponderación corregimos los desequilibrios demográficos en la elaboración de medidas de consumo agregadas. Para el análisis de las cuentas nacionales distributivas y la dinámica del consumo necesitamos una muestra representativa a nivel nacional del consumo individual. Para ello, para cada celda demográfica (g, a, q) en el año τ extraemos con reemplazo de la población de clientes activos $x_{g,a,q}^{INE}$ veces. Esto produce una muestra nacional de tamaño igual a la población adulta española para la que se puede realizar un análisis distributivo.

4. EL CONSUMO EN TIEMPO REAL TR

Con la metodología descrita en la sección anterior, agregamos todas las observaciones de consumo con frecuencia trimestral para formar una medida de consumo nacional agregada y compararla con el consumo final de los hogares oficial publicado por el INE. De igual manera, comparamos el desglose del consumo de cada categoría COICOP entre nues-

tros datos y los oficiales. En ambos casos la correlación entre nuestros indicadores y las cifras oficiales es significativamente alta, a pesar de los enfoques y metodologías distintas para llegar a las cifras agregadas, con la ventaja de que nuestros indicadores tienen una frecuencia diaria, pudiendo dar respuestas rápidas a la evolución del consumo, así como gran detalle regional, sectorial y por características del consumidor. De esta forma, describimos a continuación la evolución del consumo diario; el consumo agregado de los hogares a nivel provincial; una medida de alta frecuencia de la cesta de consumo de los hogares nacionales; y un desglose del consumo por medio de pago. Estos ejemplos ponen de manifiesto como nuestros datos pueden ayudar a generar nuevas medidas relevantes para el desarrollo de políticas, no presentes en los datos oficiales.

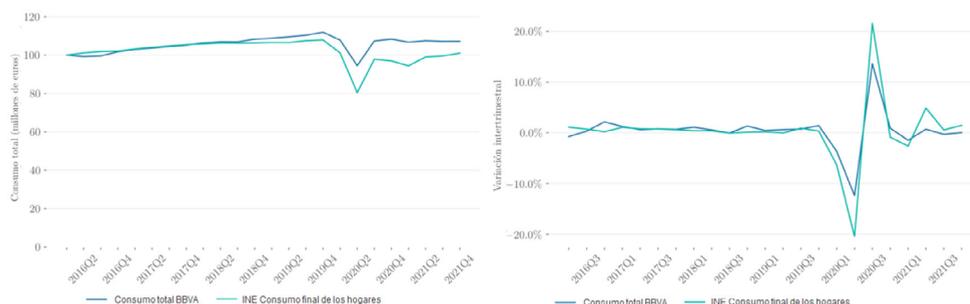
4.1. Relación con la contabilidad nacional

La estimación del consumo de los hogares en las cuentas nacionales se basa en diversas fuentes de información, como las ventas de las empresas registradas a través de encuesta y los requisitos de información obligatoria, los datos administrativos sobre, por ejemplo, las compras de automóviles, y las encuestas a los hogares para compras específicas, por ejemplo, el Panel de Consumo Alimentario. Estas diversas fuentes de datos se combinan después en un modelo estadístico y el INE publica el consumo final de los hogares con una periodicidad trimestral y presenta los desgloses por COICOP con una periodicidad anual.

La **figura 4** compara las series agregadas trimestrales del INE en términos reales, tanto en niveles como en tasas de crecimiento intertrimestral, con nuestros datos, excluyendo los efectos estacionales en ambas series. Las series se deflactan utilizando el índice de precios al consumo (IPC) oficial definido a nivel de mes-región-COICOP. Ambas series tienen una alta correlación tanto en niveles como en tasas de crecimiento con frecuencia trimestral pese a que se construyen de forma distinta. Aunque seguimos cuidadosamente las definiciones de la contabilidad nacional al diseñar qué transacciones filtrar, obtenemos el consumo agre-

Figura 4.

Consumo agregado de BBVA frente a la contabilidad nacional (real)



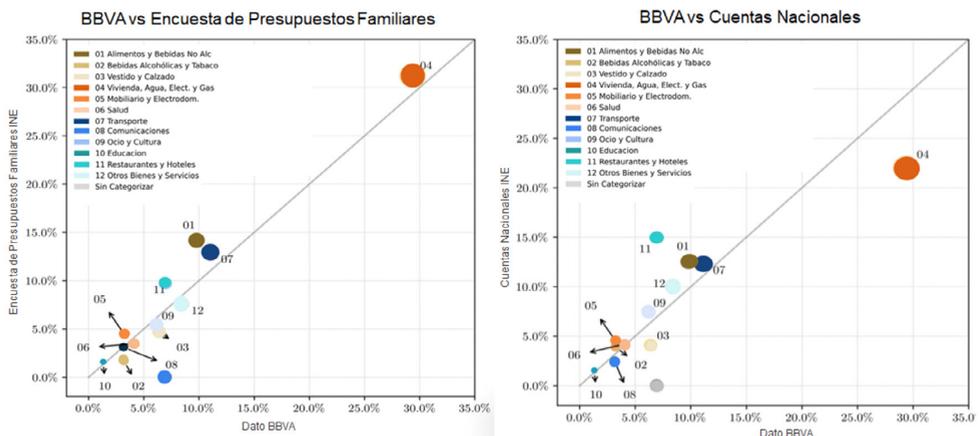
gado mediante una simple suma ponderada sobre las medidas de consumo individuales, a diferencia del SEC (Sistema Europeo de Cuentas, que el INE utiliza para elaborar las cuentas nacionales), que define un complejo conjunto de procesos para combinar múltiples fuentes de datos en los agregados de las cuentas nacionales.

Una discrepancia notable en las series se produce durante la crisis del COVID-19, cuando observamos que tanto la caída como la recuperación del consumo son más estables según nuestra medida que según los datos oficiales. Es difícil determinar cuál de estas series es más precisa en captar la dinámica del consumo durante la crisis. Una hipótesis es que los datos oficiales utilizan como insumo las ventas de las empresas, pero que durante y después de la pandemia los consumidores comenzaron a adquirir insumos de empresas diferentes a las incluidas en el modelo del INE. Esto implicaría que captaríamos un mayor consumo y por tanto generaríamos un nivel más alto.

A nivel sectorial, comparamos la distribución del consumo agregado entre las categorías *COICOP* según las cuentas nacionales y la *EPF* con nuestros datos en 2019. En estos últimos, distribuimos el efectivo entre las categorías *COICOP* utilizando los mismos porcentajes que observamos para el gasto con tarjeta presencial. El supuesto es que el gasto en efectivo y en tarjetas presencial son sustitutos y, por tanto, deberían gastarse en artículos relacionados. La *figura 5* compara los niveles (logarítmicos) de consumo de las diferentes medidas con nuestros datos. En general, existe una estrecha relación entre los niveles de consumo específicos *COICOP* de las cuentas nacionales y los de la *EPF* y nuestros datos. Sin embargo, nuestros datos tienen una mejor representatividad de las cuentas nacionales: el error absoluto medio con respecto a las cuentas nacionales (*EPF*) es de 0,266 (0,333) puntos logarítmicos en todas las categorías *COICOP*. La mayor diferencia aparece en *COICOP 2* “Bebidas alcohólicas y

Figura 5.

Distribución del gasto en las categorías de la *COICOP*

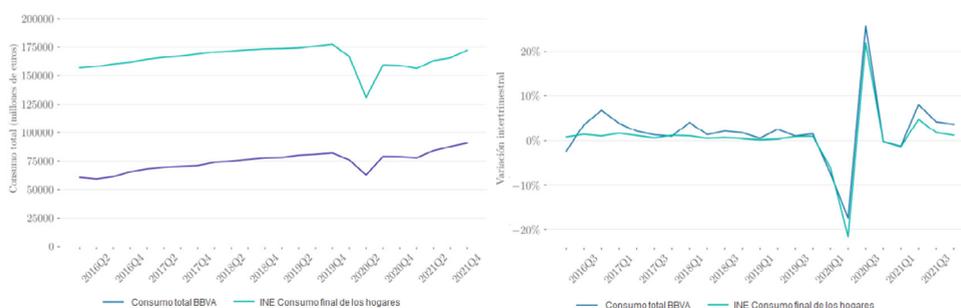


tabaco”. Los hogares parecen especialmente propensos a infradeclarar el gasto en esta categoría debido a la estigmatización social, mientras que nuestros datos coinciden con las cuentas nacionales. La mayor divergencia entre los datos naturales y las cuentas nacionales se da en COICOP 3 “Vestido y calzado”. Esto se debe probablemente a la atribución de dinero en efectivo en proporción al gasto con tarjeta presencial, donde esta COICOP está sobrerrepresentada (como se ve en la [figura 3](#)).

Por último, para mostrar el valor añadido de la medida de consumo total construida, mostramos la comparativa de nuestros datos con los datos oficiales si tenemos en cuenta una medida de consumo agregada derivada únicamente del gasto con tarjeta. El gasto con tarjeta se ha utilizado recientemente para rastrear los efectos del COVID-19 en varios trabajos (Andersen *et al.*, 2020; Carvalho *et al.*, 2021). ¿Hasta qué punto el gasto con tarjeta nos permite monitorizar el consumo agregado? En la [figura 6](#) se representan las mismas curvas que en la [figura 4](#), pero utilizando únicamente la parte del consumo derivada del gasto con tarjeta, incluida la retirada de efectivo con tarjeta. La serie de datos de tarjetas tiene una escasa cobertura agregada del consumo de las cuentas nacionales. Además, su tasa de crecimiento tiene un notable sesgo al alza que no está presente en la medida completa del consumo construida. La tasa media de crecimiento intertrimestral del consumo oficial de los hogares entre 2016 y 2021 es del 0,55 %, mientras la tasa de crecimiento de la medida completa de consumo es del 0,83 % y la tasa de crecimiento de la medida de consumo basada en tarjeta es del 2,01 %. Es por tanto que el gasto con tarjeta tiene notables limitaciones para monitorizar la evolución del consumo.

Figura 6.

Consumo agregado de BBVA frente a la contabilidad nacional (solo tarjetas)



4.2. Nuevos indicadores del dato en tiempo real y alta definición

Una de las principales ventajas de nuestros datos es su alta granularidad, pudiendo producir nuevas medidas de contabilidad nacional que van más allá de lo que ya está disponible en los institutos de estadística. A continuación mostramos varios ejemplos que lo ilustran.

4.2.1. Cuentas nacionales en alta frecuencia

En tiempos de alta incertidumbre económica como los actuales es importante comprender cómo evoluciona la economía en tiempo real. La definición de t en $c_{t:g,a,q}^W$ depende del usuario y puede ajustarse a la frecuencia que se necesite. Para ilustrar una versión de alta frecuencia del consumo agregado, la *figura 7* toma t como un día. La vivienda se imputa a nivel mensual, por lo que la dividimos por igual entre todos los días de un mes determinado. Además, para evitar que los grandes pagos en un solo día influyan en la medida (por ejemplo, las fechas periódicas en las que se pagan las facturas de suministros), calculamos una media móvil no centrada de 28 días. Por último, tenemos en cuenta la estacionalidad diaria trazando las tasas de crecimiento interanual con respecto a los días comparables (por ejemplo, el crecimiento del consumo desde el primer domingo del año $t - 1$ hasta el primer domingo del año t). Como cabría esperar, la serie diaria es más volátil –en parte debido a los problemas de calidad de los datos en 2015 T2-2016 T4– que la serie trimestral, pero también es capaz de captar el impacto económico de las grandes perturbaciones. La caída del consumo agregado debida al confinamiento del COVID-19 es severa e inmediata.

Otra medida de alta frecuencia que resulta de interés es la cesta de consumo de los consumidores. La *figura 7* muestra la evolución de las cuotas de consumo de las categorías COICOP con una frecuencia mensual, donde de nuevo se observa un cambio drástico debido al COVID-19. El gasto en restaurantes y hoteles se desploma en 2020, mientras que otras categorías, como la comunicación, permanecen relativamente estables a lo largo de la muestra.

Figura 7.

Crecimiento del consumo diario (media móvil interanual de 28 días)

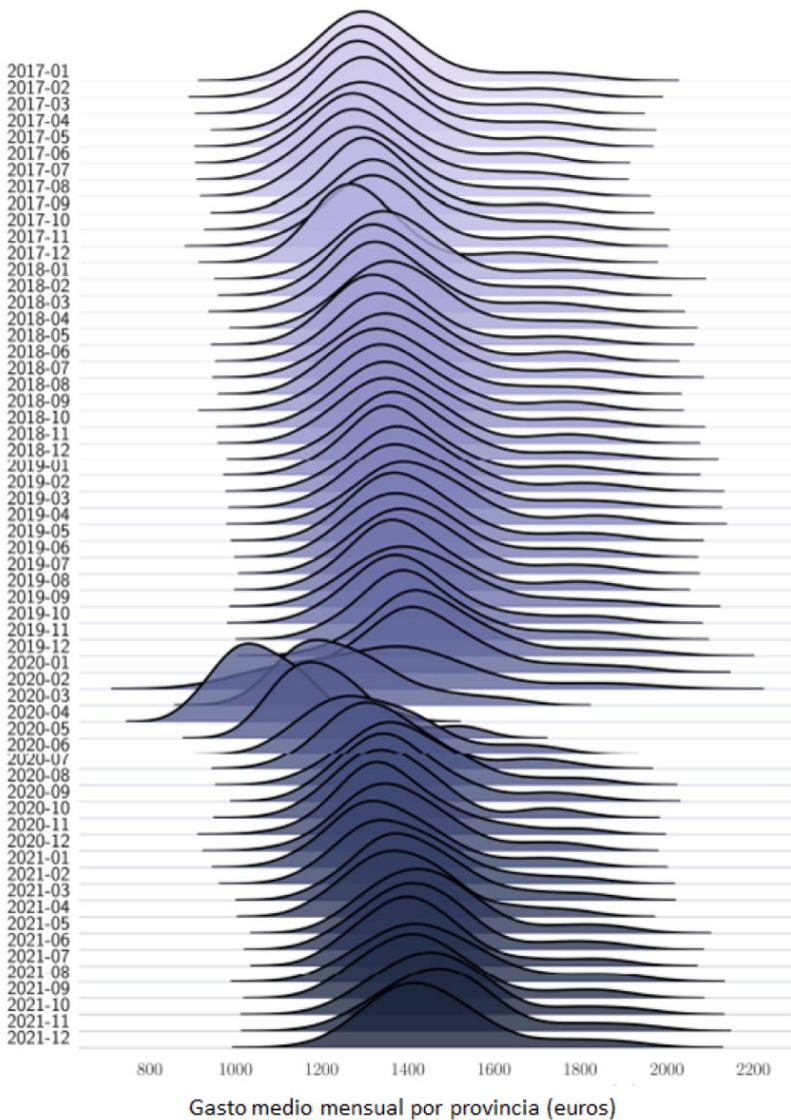


4.2.2. Cuentas nacionales geográficamente detalladas

Otra de las ventajas de nuestros datos es el detalle geográfico, que nos deja una huella precisa la evolución y desigualdades del consumo a nivel regional. La despoblación rural ha

Figura 8.

Distribución del consumo por persona por comunidades autónomas



sido una de las principales preocupaciones de la última década, pero no existen estadísticas regionales nacionales que permitan estudiar esta desigualdad regional con detalle. En España, el INE elabora estimaciones del PIB a nivel regional, pero sin desagregar el consumo y en ningún caso elabora estadísticas oficiales a un nivel provincial más detallado. Es aquí donde nuestros datos, de nuevo, aportan un valor diferencial.

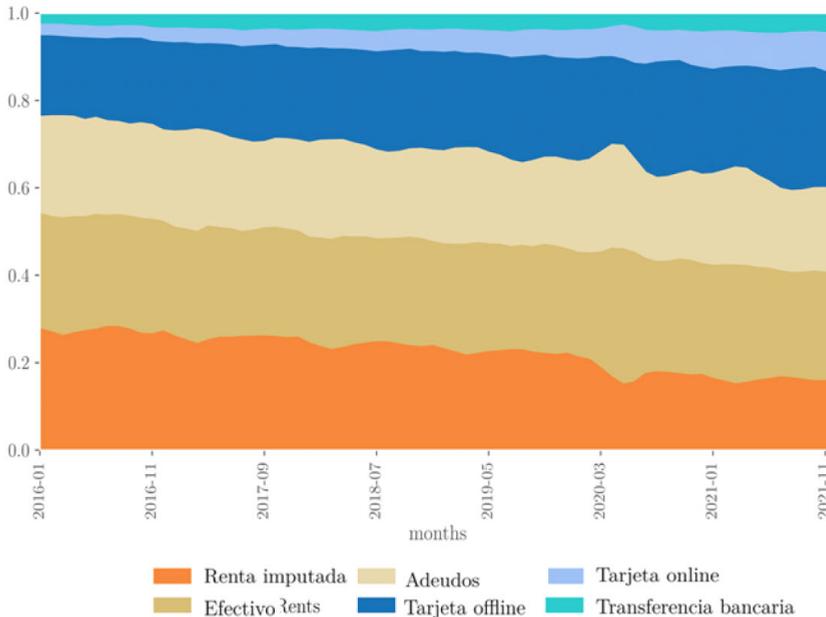
La *figura 8* ilustra la desigualdad provincial medida con nuestros datos. Para cada una de las 52 provincias españolas, calculamos el consumo agregado mensual desestacionalizado y lo dividimos por el número de adultos de la provincia. En general, se observa una masa de provincias en el centro de la distribución y una larga cola derecha de provincias de mayor consumo. De esta forma, estas estadísticas pueden constituir una importante base de datos para el diseño de políticas “inteligentes” que permitan atacar la desigualdad geográfica regional en España.

4.2.3. Cuentas nacionales por medio de pago

Como hemos destacado a lo largo del capítulo, nuestro estudio monitoriza las transacciones financieras de todos los medios de pago a través de los cuales se efectúa el consumo. Aunque existen algunas encuestas que recogen la frecuencia con la que los individuos utilizan

Figura 9.

Distribución por medio de pago



los diferentes medios de pago, éstas no se restringen a los pagos relacionados específicamente con el consumo, por lo que nuestros indicadores aportan un valor diferencial. La **figura 9** muestra la evolución del medio de pago utilizado a lo largo de nuestro ejercicio. Se observa un aumento constante del uso de las transacciones online y un descenso marcado del uso del efectivo.

5. LA ECONOMÍA EN ALTA DEFINICIÓN: LA DISTRIBUCIÓN DEL CONSUMO EN LAS CUENTAS NACIONALES

Una vez bien procesados y clasificados según los principios de contabilidad nacional, los datos de transacciones financieras logran una alta correspondencia con las cuentas nacionales publicadas por el INE (Buda *et al.*, 2022). Esto supone que, además de utilizar estos datos para el seguimiento del consumo en tiempo real, los microdatos subyacentes pueden ser utilizados para construir cuentas nacionales distributivas del consumo. Es decir, pueden ser utilizados para describir la distribución de los niveles de consumo y sus categorías por diversas variables como nivel de consumo, renta, edad... incluyendo cuestiones relacionadas como la desigualdad y su distribución en el tiempo en línea con los trabajos desarrollados por Piketty *et al.* (2018).

Desde el trabajo seminal de Piketty, Saez, Zucman (2018), ya existen cuentas nacionales distributivas de la renta para un gran número de países incluido España. Esta metodología es macroconsistente en el sentido que combina los agregados de las cuentas nacionales existentes, los censos, las encuestas de hogares y los microdatos de los impuestos sobre la renta. Sus trabajos han tenido una gran repercusión en los debates académicos y públicos sobre la desigualdad de ingresos y su evolución en el tiempo.

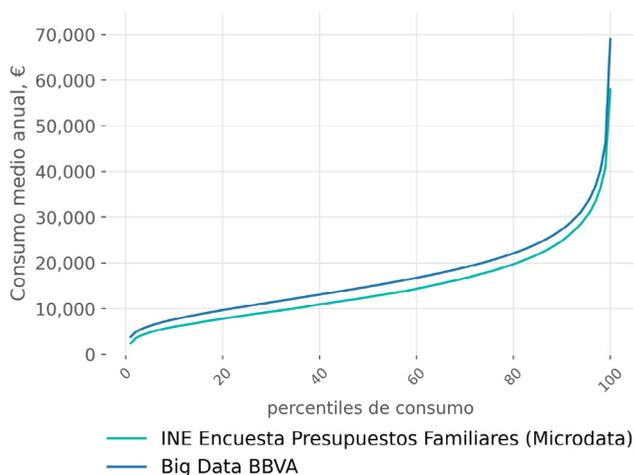
Sin embargo, y hasta donde sabemos, las cuentas nacionales de distribución del consumo son prácticamente inexistentes. Nuestras cuentas nacionales distributivas del consumo captan el 100 % del consumo agregado, lo que nos permite calcular el consumo para cada percentil de la distribución del consumo de forma coherente con los agregados macroeconómicos.

La **figura 10** representa la distribución transversal del consumo a través de los percentiles de consumo en 2017, con el eje Y representando el consumo medio anual de un adulto español en un percentil determinado de la distribución de consumo. El consumo medio de los adultos derivado de esta distribución coincide con la cifra de consumo agregado español por adulto, que en 2017 se situaba en 16.907 euros (56 % del PIB por adulto en España). Esta distribución es además muy similar cuando se compara con la distribución equivalente de la *Encuesta de Presupuestos Familiares Española (EPF)*.

Un primer indicio de la magnitud de la desigualdad en el consumo viene dado entonces por el hecho de que el adulto medio español en 2017 consumió 14.971 euros, un 12 % menos

Figura 10.

Distribución del consumo en España: *big data* vs. Encuesta de Presupuestos Familiares



que el consumidor medio en España. La desigualdad del consumo se ve reforzada al observar directamente las colas de la distribución del consumo. Así, el consumidor adulto típico en el percentil 90 de la distribución del consumo de 2017 consumió aproximadamente dos veces más que el consumidor medio (28.115 euros). En otras palabras, la conocida relación entre los percentiles 90 y 50 (p_{90}/p_{50}) en 2017 es de 1,87. Si nos acercamos más a la cola de la distribución del consumo, el consumidor medio del 1 % superior consumió unos 68.893 euros, lo que implica una relación p_{99}/p_{50} de 4,6. En el extremo opuesto, un adulto típico en el percentil décimo inferior de la distribución de consumo de 2017 consumió sólo 7.869 euros, aproximadamente la mitad del consumidor adulto mediano y 3,6 veces menos que el 10 % superior entre adultos.

Hasta ahora, hemos centrado nuestra atención en la distribución del consumo total por adulto. Sin embargo, la elevada granularidad de nuestro trabajo nos permite desglosar los resultados del consumo por las principales categorías de consumo oficiales (COICOP) como hemos mostrado en secciones anteriores.

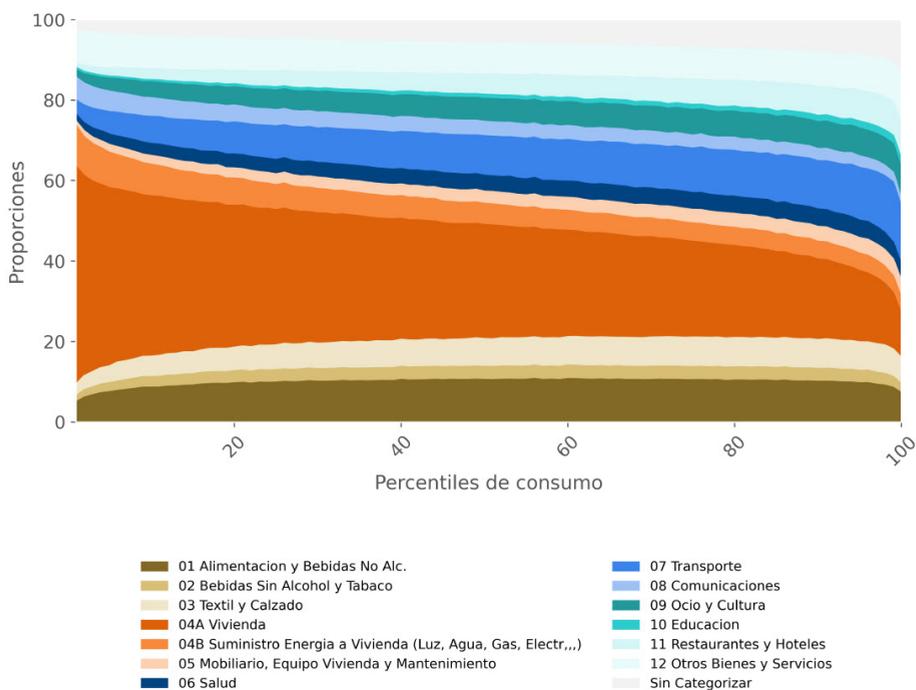
Podemos obtener un resumen de la información de la desigualdad por tipo de consumo agrupando las categorías en dos grandes subgrupos: necesidades básicas y bienes de lujo².

² Para ello Incluimos en las necesidades de consumo los alimentos y bebidas no alcohólicas (categoría 01 de la COICOP), el alcohol y el tabaco (02), el vestido y el calzado (03), el gasto en vivienda y suministros (4A y 4B) y la salud (06). Por el contrario, incluimos en el gasto de bienes de lujo, el menaje de hogar (05), el transporte (07), las comunicaciones (08), el ocio y la cultura (09), la educación (10), los restaurantes y hoteles (11), los bienes y servicios diversos (12) y la categoría residual no clasificada, los gastos no clasificados. Procedemos a nuestro análisis basándonos en estas agrupaciones.

La **figura 11** muestra la distribución del consumo por percentiles y categorías durante el año 2017. Si tenemos en cuenta en primer lugar la cuota de gasto en necesidades (representado por tonalidades marrones y naranjas), éstas constituyen el 57,4 % del consumo total del adulto medio en la distribución del consumo. En consonancia con el concepto de necesidades, este porcentaje disminuye fuertemente a lo largo de la distribución del consumo, representando el 67 % del consumo total de los adultos del 10 % inferior, el 49 % del consumo total del 10 % superior y sólo el 29 % del 0,1 % superior. Un resultado importante es que, aunque el consumo total de artículos de primera necesidad aumenta con el consumo total (como se desprende del panel (a) para los niveles de gasto), la desigualdad de consumo implícita derivada del consumo de artículos de primera necesidad es algo menor que la del consumo total. Por ejemplo, la relación p90-p50 es de 1,60 (en relación con el 1,87 del consumo total) y la proporción del 10 % superior del consumo agregado de artículos de primera necesidad es de 0,19 (en relación con el 0,22 del consumo agregado total).

Figura 11.

Distribución del consumo por percentiles y categorías en 2017



Por el contrario, la distribución del consumo de bienes de lujo es muy desigual. En efecto, el 50 % inferior de la distribución del consumo sólo representa el 24 % del gasto total en lujo, mientras que el 10 % superior representa un desproporcionado 30 %. Como era de

esperar, el consumo de bienes de lujo se concentra en la parte superior y, por ejemplo, representa el 71 % del consumo del adulto medio en el 0,1 % superior de la distribución del consumo. En resumen, y complementando toda esta información con el índice de Gini como medida para resumir la desigualdad en la distribución, los resultados presentados implican que el consumo de bienes de lujo está distribuido un 38 % de manera más desigual que el consumo total.

Otra de las ventajas de los datos de las transacciones financieras es que incluyen información adicional sobre cada consumidor (edad, género, ingreso, provincia...), por lo que podemos presentar estas cuentas distributivas del consumo desagregadas por características demográficas.

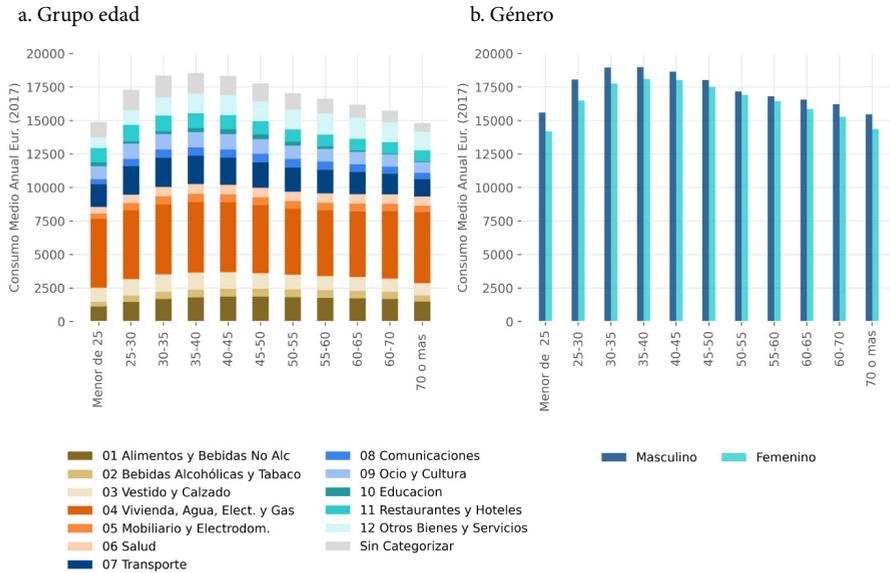
Como ejemplo las [figuras 12a y 12b](#), que muestran la distribución del consumo de 2017 por grupos de edad y género. En la primera, el eje Y indica tanto el consumo total medio de los adultos en una categoría de edad determinada como su desglose entre las categorías de consumo *COICOP*. La pauta de consumo en forma de U invertida reflejada en la literatura³ es también evidente en nuestra muestra, en la que observamos que el consumo de los adultos crece a lo largo de los 20 y los 30 años, alcanza su máximo en la mediana edad y disminuye suavemente a partir de entonces. Es decir, a lo largo del ciclo vital se observa un aumento del 20 % en el consumo desde la juventud hasta la mediana edad, seguido de un descenso del mismo tamaño en el consumo hasta la vejez. Dada la elevada granularidad de los datos es posible explorar los ricos metadatos asociados a cada transacción para obtener una contabilidad distributiva de esta U invertida por edad y categorías de consumo. En particular, se confirma que el descenso del consumo después de la edad media es en parte el resultado de un descenso en el consumo de restaurantes y hoteles, transporte y, en menor medida, ropa y calzado. A diferencia de los resultados de Aguiar y Hurst (2013) para EE. UU., también encontramos un papel importante para la disminución de los gastos de educación, de ocio y cultura.

La información nos permite extender el análisis a la diferencias de género ([figura 12b](#)). Aquí, el consumo agregado muestra una brecha de género del 6 % en el consumo en 2017. El hombre adulto medio en España consumió 17.390 euros, mientras que la mujer adulta media consumió aproximadamente 1.000 euros menos, con 16.399 euros. Curiosamente, esta diferencia no es constante a lo largo del ciclo vital de hombres y mujeres. Tanto los hombres como las mujeres muestran un claro perfil de ciclo vital que alcanza su punto máximo en la mediana edad, pero la brecha de consumo entre ambos sexos es mayor para los que tienen entre 20 y 30 años, y luego disminuye lentamente hasta alcanzar un mínimo casi paritario para los que tienen entre 50 y 55 años, mientras que vuelve a abrirse a partir de los 60⁴.

³ Véase Aguiar y Hurst (2013); Fernández-Villaverde y Krueger (2007), entre otros.

⁴ Este hecho es coherente con una penalización de la brecha de ingresos de género ampliamente documentada debido a las interrupciones de la trayectoria profesional durante las edades típicas de maternidad: véase, por ejemplo, Guvenen, Kaplan y Song (2020) como estudio reciente.

Figura 12.

Distribución del consumo en España por edad y género (2017)**6. UTILIZACIÓN DEL *BIG DATA* PARA POLÍTICA ECONÓMICA**

Las posibilidades de obtener la información *big data* de las transacciones financieras en tiempo real y alta definición convierten a este tipo de datos en idóneos para ser utilizados en materia de política económica. En particular, hay una tendencia creciente durante los últimos años a utilizar estos datos como indicadores para el seguimiento en tiempo real de la actividad económica, el análisis de la heterogeneidad y desigualdad y el análisis de inferencia causal para la evaluación de política económica.

La inmediata disponibilidad de los datos favorece una rápida respuesta en términos de política económica, tal como se pudo apreciar durante el COVID-19, sobre todo en el primer y segundo trimestre de 2020. El uso de esta información ofrece la oportunidad de extraer señales económicas casi en tiempo real y anticipar series económicas antes de que se publiquen las cifras oficiales.

La información obtenida de las transacciones financieras se ha utilizado bien para evaluar directamente la actividad económica en tiempo real. En el caso de España tanto Carvalho *et al.* (2021) como Mestre *et al.* (2022) mostraron ya en 2020 como utilizar los datos de transacciones con tarjetas para el seguimiento de la actividad económica. Más recientemente, Buda *et al.* (2022) muestra cómo se puede hacer un seguimiento en tiempo real no sólo del consumo de tarjetas (cerca de un 35 % del total) sino del resto de las transacciones comple-

tando así el 100 % del consumo y sus categorías oficiales (que se publican con más de un año de retraso oficialmente). La información de las transacciones puede ser introducida también en modelos de *nowcasting* junto a otras variables.

El análisis de la heterogeneidad y las cuentas distribucionales de la renta o el consumo también se ha visto reforzado con los datos de las transacciones financieras. Este puede constituir un elemento importante dentro del campo del análisis de la desigualdad de la renta (Mestre *et al.*, 2022 y Buda *et al.*, 2022) y del consumo (Buda *et al.*, 2022). Este último trabajo (Buda *et al.*, 2022) muestra un elevado grado de consistencia de la distribución de la renta con las nuevas cuentas distribucionales de la renta GRID para la economía española y un elevado grado de ajuste en la desigualdad del consumo con la obtenida en la encuesta oficial de presupuestos familiares. La alta granularidad de los datos también ha sido utilizada para analizar el impacto de la inflación en la renta de las familias a través de diferentes canales (Cardoso *et al.*, 2022).

7. CONCLUSIONES

Los abundantes datos de transacciones financieras que se producen de forma natural pueden utilizarse a un coste relativamente bajo para generar información compleja, cuidada, precisa y exhaustiva sobre la actividad económica. Nuestro trabajo aboga por el uso de estos datos tanto para la construcción de cuentas nacionales agregadas y su utilización en tiempo real, así como la información que se genera en alta definición en forma de cuentas distributivas para el estudio de la microestructura de la actividad económica.

La disponibilidad en tiempo real de la información del consumo total (55 % de la economía del PIB español) constituyen un avance notable para el campo de la coyuntura económica. No menos importante, es el hecho de que las doce categorías oficiales también están disponibles en tiempo real, cuando son oficialmente publicadas una vez al año.

Además, las buenas propiedades de agregación de los datos permiten un análisis distributivo del consumo agregado, proporcionando una descripción rica y macroconsistente de la desigualdad del consumo y su evolución temporal. Todo esto es posible porque los datos de las transacciones, una vez organizados adecuadamente, pueden desplegarse como una encuesta de consumo de alta calidad, a gran escala y en tiempo real, que contiene tanto información sobre las decisiones de consumo de millones de individuos como ricos metadatos que etiquetan miles de millones de transacciones.

Evidentemente, hay una plétora de covariables adicionales dentro de los datos de transacciones financieras que pueden utilizarse para ir más allá del consumo y hacer un mejor seguimiento de otras áreas de la actividad económica. Por ejemplo, los datos de las transacciones incluyen una gran cantidad de información a nivel de empresa que puede utilizarse para comprender la actividad de producción.

Creemos que también es posible analizar más a fondo el funcionamiento del sector exterior y la actividad gubernamental, o generar tablas de insumo-producto regionales y sectoriales, un objeto clave para las cuentas nacionales. Por último, volviendo al consumo, a nivel microeconómico también es posible aumentar nuestro panel de consumo con otras covariables (principalmente la renta y la riqueza), lo que permite comprender mejor las decisiones de consumo-ahorro y ayudar al desarrollo de la teoría económica.

Referencias

- ANDERSEN, A. L., HANSEN, E. T., JOHANNESSEN, N. y SHERIDAN, A. (2020). Consumer responses to the covid-19 crisis: Evidence from bank account transaction data. *CEBI Working Paper Series*, No. 1820.
- ASPACHS, O., DURANTE, R., GRAZIANO, A., MESTRES, J., MONTALVO, J. G. y REYNAL-QUEROL, M. (2002). Real-time inequality and the welfare state in motion: evidence from COVID-19 in Spain. *Economic Policy*, Volume 37, Issue 109, January 2022, pp. 165–199.
- BAKER, S. y KUENG, L. (2022). Household Financial Transaction Data. *Review of Economics* 14(1), pp.47-67.
- BARLAS, A. B., GULER, S., ORTIZ, A. y RODRIGO, T. (2020). Investment in real time and High definition: A Big data Approach. *BBVA Research Working Papers*, No. 2013.
- BEAN, C. (2016). Independent review of UK economic statistics: Final report. Technical report.
- BOUNIE, D. CAMARA, Y. y GALBRAITH, J. (2020). Consumers' mobility, expenditure and onli- neoffline substitution response to covid-19: Evidence from french transaction data. *Hal working papers*, no. 02566443.
- BUDA, G., CARVALHO, V., HANSEN, S., ORTIZ, A., RODRIGO, T. y MORA, J. (eds) (2022). DP17519 National Accounts in a World of Naturally Occurring Data: A Proof of Concept for Consumption. *CEPR Press Discussion Paper* No. 17519.
- CARDOSO, M., FERREIRA, C., LEIVA, J. M., ORTIZ, A., RODRIGO, T. y VAZQUEZ, S. (2022). The Heterogeneous Impact of Inflation on Households' Balance Sheets?. Mimeo.
- CARVALHO, V., GARCIA, J., HANSEN, S., ORTIZ, A., RODRIGO, T., RODRIGUEZ MORA, S. y RUIZ, P. (2021). Tracking the COVID-19 crisis with high-resolution transaction data. *Royal Society Open Science*, 8.
- CHETTY, R., FRIEDMAN, J. N., HENDREN, N. y STEPNER, M. (2020). How Did COVID-19 and Stabilization Policies Affect Spending and Employment? A New Real-Time Economic Tracker Based on Private Sector Data. *Working Paper*.
- COX, N., GANONG, P. NOEL, J. VAVRA, A., WONG, FARRELL, D., GREIG, F. y DEADMAN, E. (2020). Initial impacts of the pandemic on consumer behavior: Evidence from linked income, spending, and savings data. University of Chicago, Becker friedman institute for economics working paper.
- CHRONOPOULOS, D. K., LUKAS, M. y WILSON, J. O. (2020). Consumer spending responses to the covid-19 pandemic: An assessment of great britain. *Working papers in responsible banking and finance* no.20-012.
- EHRlich, G., HALTIWANGER, J. C., JARMIN, R. S., JOHNSON, D. y SHAPIRO, M. D. (2022). Re-engineering Key National Economic Indicators. En *Big Data for Twenty-First-Century Economic Statistics* (pp. 25–68). University of Chicago Press.
- EINAV, L. y KLENOW, P. (2021). Customers and retail growth. *Working Paper*, Stanford University, Stanford, CA.
- FERNANDEZ-VILLAVERDE, J. y KRUEGER, D. (2007). Consumption over the Life Cycle: Facts from Consumer Expenditure Survey Data. *The Review of Economics and Statistics*, 89(3), pp. 552–565.
- GATHERGOOD, J., LOEWENSTEIN, G., QUISPE-TORREBLANCA, E. G. y STEWART, N. (2019). The red, the black and the plastic: paying down credit card debt for hotels, not sofas. *Management Science*, 65(11), pp. 4951–5448.

- GUVENEN, F., KAPLAN, G. y SONG, J. (2020). The Glass Ceiling and the Paper Floor: Changing Gender Composition of Top Earners since the 1980s. En *NBER Macroeconomics Annual 2020*, Volume 35, pp. 309–373. University of Chicago Press.
- GUVENEN, F., PISTAFERRI, L. y VIOLANTE, G. (2022). Global Trends in Income Inequality and Income Dynamics: New Insights from GRID. *NBER Working Papers* 30524. National Bureau of Economic Research, Inc.
- HACIOGLU, S., KANZIG, D. R. y SURICO, P. (2020). Consumption in the time of covid-19: Evidence from uk transaction data. *CEPR discussion papers* no. 14733.
- PIKETTY, T., SAEZ, E. y ZUCMAN, G. (2018). Distributional National Accounts: Methods and Estimates for the United States. *The Quarterly Journal of Economics*, 133(2), pp. 553–609.

CAPÍTULO VIII

¿Sueña la inteligencia artificial con cárteles virtuales?

Jose Penalva*

La inteligencia artificial (IA) se aplica como instrumento para fijar precios en muchos sectores más allá del comercio electrónico. Se utiliza para fijar tipos de interés de préstamos, seguros, billetes de hotel y avión, alquileres, etc. En este capítulo discutimos, en el contexto de nuevos resultados que analizan el comportamiento de algoritmos en el marco de la fijación de precios, el posible impacto de este uso de la IA, y hasta qué punto las políticas de competencia pueden seguir aplicando recetas antiguas o han de adaptar sus planteamientos a este nuevo contexto.

Palabras clave: inteligencia artificial, competencia, teoría de juegos, política de precios.

* Quiero agradecer a Álvaro Cartea y a Nuria Serrano su ayuda a la hora de revisar versiones preliminares de este artículo, además de todo el apoyo que me han brindado siempre. Añadir a Patrick Wang y Harrison Waldon que junto con Álvaro forman el resto del equipo que desarrolla esta línea de investigación, y a Juan-José Ganuza que me mantiene con los pies en el suelo. También quiero agradecer al contribuyente ya que parte de la investigación sobre la que se apoya este artículo se ha financiado con un proyecto de la Agencia Estatal de Investigación (PID2019-104649RB-I00/AEI/10.13039/501100011033). Los errores son todos míos.

1. LA INTELIGENCIA ARTIFICIAL Y LA FIJACIÓN DE PRECIOS

Phillip K. Dick escribió una novela corta (magníficamente reinventada como la película *Blade Runner*) en la que describe un futuro distópico donde un cazarrecompensas llamado Rick Deckard se dedica a “retirar” (matar) androides que vuelven al planeta Tierra sin autorización. La novela gira alrededor de las cuestiones morales que surgen sobre las leyes a aplicar a androides que son cada vez más difíciles de distinguir de los humanos. El título de este capítulo distorsiona libremente el título original de la novela (*¿Sueñan los androides con ovejas eléctricas?*) como analogía a los problemas mucho más concretos y limitados a los que se enfrentan las autoridades de la competencia a la hora de lidiar con la cada vez mayor participación de la inteligencia artificial (IA) en el proceso de fijación de precios. Y, en particular, si las interpretaciones de las leyes desarrolladas para lidiar con comportamientos humanos poco competitivos necesitan modificarse cuando los precios se fijan mediante IA.

A día de hoy, la IA ocupa un espacio cada vez mayor en la fijación de precios y otras decisiones económicas. La irrupción de la IA como instrumento en la fijación de precios empezó en segmentos muy especializados y cada vez más los humanos delegan en ella decisiones sobre precios en diferentes ámbitos. Las primeras aplicaciones aparecen a la hora de fijar los precios de billetes de avión y habitaciones de hotel. Hoy en día encontramos programas de IA específicamente diseñados para estos sectores que se encargan de todo el proceso de fijación de precios y lo hace de manera automática y dinámica, como por ejemplo el programa *Airline Dynamic Pricing* de la empresa PROS. Para hoteles existen programas parecidos (en la dimensión de fijación de precios) como *Revpar Guru*, de *Rate Shopper*.

Los mercados financieros han resultado ser un campo abonado para la IA hasta tal punto que dominan ciertos mercados como los de acciones. Empresas como *Virtu* y *Citadel* se han convertido en las principales empresas de mediación y provisión de mercados en las bolsas electrónicas de todo el mundo, y lo hacen mediante algoritmos que utilizan IA. Pero esto no ocurre sólo en las bolsas. Por ejemplo, *Munich Re* es una de las empresas líderes en el sector del seguro de automoción, y utilizan la IA en su *software* de fijación de precios, *AutoML*. En el mercado de préstamos también encontramos programas de valoración de riesgos y fijación de precios como *Sopra Banking Suite*, *Lendstream*, o *HES Loanbox*. Y, naturalmente, con el crecimiento del comercio electrónico, la IA juega un papel cada vez mayor en las políticas de precios. Una parte muy significativa de las ventas en la plataforma *Amazon* se llevan a cabo en tiendas que usan la IA para fijar precios, con programas como [Amazon Algorithmic Reprice](#) (de *Feedvisor*), [PricingPRO](#) (de *PROS*), o [Incompetitor](#) (de *Intelligence Node*).

Este crecimiento en el número y uso de IA para fijar precios es algo que preocupa a los reguladores, entre otras razones porque consideran que existe un riesgo muy real que el uso de IA en la fijación de precios pueda estar facilitando que los precios aumenten y se mantengan por encima de su nivel competitivo (véase los documentos de la *Competition & Markets Authority* (2018, 2021), la *OCDE* (2017), y la *Comisión Europea* (2017)). Como muestra de este fenómeno podemos leer en un [artículo online](#) reciente en *propublica.org* una investigación periodística que relaciona el incremento sustancial en los precios de los alquileres de

viviendas y locales en diversas ciudades de EE. UU. con la compra y aplicación del programa RealPage, o el trabajo de investigación de Assad *et al.* (2021) que asocia aumentos de precios de la gasolina con la adopción de programas de gestión de precios automatizados.

Para poder plantearnos cómo regular la IA en su aplicación al problema de fijación de precios, un problema fundamental es entender qué tipo de comportamiento es capaz de generar y qué le lleva a fijar precios más o menos competitivos. Para esto hay que tener en cuenta que en el problema de fijación de precios los algoritmos no son pasivos. Éstos reaccionan a lo que pasa a su alrededor, y a su vez, lo que hace un algoritmo afecta a lo que observan los demás, y esta interacción puede ser muy compleja. Muchos de los algoritmos de IA se han estudiado en problemas aislados, pero cuando se implementan, muchas veces acaban interactuando entre ellos, y no sabemos hacia dónde les lleva el delicado baile de precios digital que se genera.

En este capítulo se describe el trabajo de investigación que el autor está llevando a cabo con sus compañeros del Oxford-Man Institute, Álvaro Cartea y Patrick Chang, y con Harrison Waldon de la Universidad de Texas, en Austin. En este trabajo, plasmado en dos artículos científicos (Cartea, Chang y Penalva, 2022; Cartea *et al.*, 2022) se utilizan las herramientas de aproximación estocástica para desarrollar un sistema de ecuaciones que permite describir cómo interactúan los algoritmos cuando juegan unos contra otros. Aplicando estas ecuaciones encontramos que si la IA utiliza uno de los algoritmos de referencia, *Q-learning*, la interacción entre algoritmos puede generar precios altos y colusión tácita, sin necesidad de comunicarse entre ellos. También encontramos que los algoritmos aprenden a coordinarse de maneras inesperadas dando lugar a patrones de comportamiento sorprendentes.

2. EL JUEGO DEL PRISIONERO: COMPETENCIA Y COLUSIÓN

El proceso de fijación de precios es muy complejo y una de las principales razones por las que la IA aporta valor en tantos sectores es porque puede incorporar de manera rápida, sistemática, y efectiva muchas variables relevantes. Pongamos por ejemplo la fijación de precios (intereses) de préstamos. En este mercado el riesgo de crédito es fundamental a la hora de elegir el tipo de interés que ofrecer. Si fijas un tipo de interés muy alto pierdes clientes, y si lo fijas muy bajo tienes muchos clientes que por su perfil de riesgo te pueden generar más costes que beneficios. Pero determinar el perfil de riesgo y, por lo tanto, un tipo de interés adecuado depende de muchas variables: la situación financiera y patrimonial del cliente, su historial, su situación laboral, etc. La IA ofrece la posibilidad de combinar de una manera rápida y eficiente mucha y muy variada información sobre los clientes, lo que facilita el análisis del perfil de riesgo de los clientes y por tanto el tipo de interés adecuado. En el eCommerce, la IA te permite recopilar y combinar información muy variada no solo de potenciales clientes sino también de la situación del mercado, sobre todo qué precios están ofertando tus competidores, y así optimizar la estrategia de precios. De la misma manera, compañías aéreas y hoteles utilizan la IA para, entre otras cosas, identificar patrones de demanda que les permita obtener una mejor combinación de precios por asiento y ocupación. En todos estos casos, además

de la importancia de una agregación y procesamiento de información adecuados, la selección de la política de precios óptima incluye dos características principales y comunes: la primera es que con un precio más bajo atraes más consumidores, y la segunda es que la IA permite recoger datos y revisar precios continuamente. Estas dos características son las que queremos capturar en nuestro modelo de competencia entre algoritmos.

Cuadro 1.

Castigos en el dilema del prisionero

Castigo Jugador 1	Jugador 2	
	Callar (C)	Delatar (D)
Callar (C)	Castigo bajo, castigo bajo	Castigo máximo, sin condena
Delatar (D)	Sin condena, castigo máximo	Castigo alto, castigo alto

Como modelo, el juego del dilema del prisionero (DdP) nos permite capturar de una manera sencilla esta interacción estratégica en un contexto de competencia entre dos participantes. En la versión clásica del DdP dos participantes deciden entre dos acciones: callar (C) o delatar (D). Dependiendo de lo que hagan los dos, los resultados que obtiene cada uno varían tal y como se describe en el **cuadro 1**. En caso de que ambos elijan C, ambos irán a prisión pero durante un periodo relativamente corto de tiempo, ya que las pruebas en su contra están limitadas. Si ambos elijen D acaban mucho peor, ya que los dos generan nuevas evidencias en su contra. Pero no reciben el castigo máximo por haber cooperado con el fiscal, delatando al otro. Sin embargo, lo peor que puede pasar es que uno se calle (C) y el otro delate (D). En este caso, uno recibe la pena máxima, y el otro se libra de la cárcel. La propiedad que caracteriza al DdP es que lo óptimo es D, independientemente de lo que haga el oponente. Si el oponente calla, lo mejor es delatar para así librarse de la cárcel. Si el oponente delata, lo mejor es delatar también para reducir condena. Por lo tanto, según el concepto de solución de Nash, el único equilibrio posible es (D D). A pesar de que ambos preferirían la situación en la que ambos callan, (C C), al decidir a nivel individual lo que es óptimo hacer acaban los dos peor, (D D).

La relación entre el DdP y el problema de fijación de precios se ve si cambiamos la interpretación de lo que significan C y D. En el problema de fijación de precios los participantes deciden qué precios poner a los productos que venden. La acción C, se interpreta como ofertar un precio alto, mientras que D es ofertar un precio más bajo. Si ambos ofertan un precio alto están cooperando (C) para sostener beneficios entre competidores, mientras que al bajar precios se desvían (D) a un precio más competitivo. En términos de incentivos, la estructura es la misma que en el DdP: en lugar de recibir un castigo bajo por callar, lo que ocurre es que se obtiene un beneficio alto si ambos eligen precios altos (C C). En lugar de recibir un castigo más alto por delatar, se obtiene un beneficio más bajo si se eligen precios bajos (D D). Y finalmente, si uno fija un precio alto (C) y el oponente uno bajo (D), el oponente se lleva todo el beneficio y el otro no vende nada. Para que la situación entre el DdP y el problema de fijación de precios sea esencialmente la misma, es fundamental que el beneficio del oponente que fija precio bajo (D) cuando el otro fija precio alto (C) sea mayor que el beneficio que obtendría si ambos se repartieran el mercado con precios altos (C C), pero esto no es difícil que se cumpla.

Por todo esto se utiliza el modelo del DdP para estudiar problemas básicos de competencia en fijación de precios. Y dada su sencillez y amplia utilidad, el modelo del DdP se ha estudiado en profundidad. Lo que hemos descrito es el modelo *one-shot* o estático. El modelo donde los participantes juegan una sola vez. En términos de implicaciones para la fijación de precios, el hecho de que el único equilibrio de Nash de este juego (estático) sea que los dos fijen precios bajos, (*D D*), implica que el resultado de la competencia en precios lleva a precios bajos, a pesar de que los competidores preferirían coordinarse para poner precios más altos y obtener mayores beneficios. Pero si el juego se repite, es decir, si los participantes juegan repetidamente al DdP la interacción estratégica se complica. Los jugadores empiezan a tener en consideración las consecuencias de sus decisiones no sólo durante la partida de DdP que están jugando ahora, sino también el efecto que puedan tener estas decisiones en futuras rondas del DdP. En tal caso la teoría de juegos también nos dice (por medio de lo que se conoce como el *Folk Theorem*, o teorema de tradición oral) que la competencia en precios repetida puede dar lugar a precios altos en el DdP. De manera más concreta, el teorema dice que cuando ambos oponentes interactúan de una manera repetida, los beneficios obtenidos de cooperar (*C C*) se pueden obtener como parte de un equilibrio de Nash del juego repetido. Esencialmente, la teoría establece que puede ser óptimo para ambos oponentes fijar y mantener precios altos (*C*) cuando hay una interacción repetida como la que permite la IA. La interacción repetida introduce la posibilidad de iniciar con precios altos (*C C*), y si alguien se desvía y baja precios (*D*), se puede responder bajando todos los precios en el futuro, lo que comúnmente se describe como una guerra de precios. La amenaza de una guerra de precios hace que el posible beneficio temporal de recortar precios hoy, no compense la futura pérdida de beneficios que provoca el abandonar la actual situación de cooperación y entrar en una guerra de precios. Por lo tanto, la posibilidad de futuras represalias en el juego repetido hace que sea posible generar incentivos para sostener acciones que no son óptimas en el corto plazo (y por lo tanto, no forman parte de un equilibrio de Nash en el juego estático). Y, en el caso de la competencia en precios, la interacción repetida puede dar lugar a una falta de competencia en precios.

Esta posible falta de competencia en precios es uno de los principales problemas al que se enfrentan las autoridades de competencia de todo el mundo, ya que daña a los consumidores, que son los que acaban teniendo que decidir entre pagar precios más altos o ser excluidos del mercado. El argumento fundamental sobre el que se basan las autoridades de competencia es la presencia de colusión. Colusión, según la teoría económica, es la práctica de sostener precios altos por medio de un mecanismo de premio-castigo (PC), o, en un lenguaje más coloquial, de palo y zanahoria. El concepto fundamental es que el uso de mecanismos de PC implica una estrategia consciente y voluntaria de intentar sostener precios por encima de sus niveles competitivos (precios supracompetitivos) y, por lo tanto, la causa de que los precios sean altos. En base a este argumento, la adopción por parte de competidores de estrategias colusivas es una práctica anticompetitiva y por lo tanto perseguible y punible.

Las autoridades de competencia han desarrollado estrategias y métodos para identificar y perseguir posibles casos de colusión entre humanos. En la práctica, a la hora de perseguir colusión las autoridades de competencia intentan demostrar que existe algún tipo de acuerdo

(contractual o no) entre competidores para implementar estos tipos de estrategias de PC. En consecuencia, lo fundamental es que haya algún acuerdo o conspiración para no competir, ya que la ley no obliga a competir. Y para demostrarlo, tradicionalmente las autoridades de la competencia tienen que encontrar evidencia convincente de que los comportamientos observados no podrían ocurrir de manera independiente, y que los actores han tomado decisiones que han servido como instrumento de comunicación entre las partes.

3. ¿CÓMO APRENDE LA INTELIGENCIA ARTIFICIAL MIENTRAS COMPITE?

Los métodos de las autoridades de competencia y las estrategias de prueba y evidencia se han desarrollado en un contexto donde los precios los fijan humanos. Pero la pregunta que nos surge es si estos métodos son apropiados en un contexto donde los precios se establecen por medio de algoritmos. Para intentar responder a esta pregunta, el primer paso es comprender cómo se comportan estos algoritmos y para ello hablaremos primero de cómo funcionan los algoritmos de IA de una manera general.

Como dijimos anteriormente, las empresas usan IA para combinar información y utilizarla en la toma de decisiones. Podemos pensar en la IA como una caja negra donde se introduce información y de la que se obtiene una propuesta de decisión (un precio). Existen varios tipos de cajas según el método de aprendizaje que utilicen. En el caso que nos ocupa hablamos de *Reinforcement Learning (RL)* como método de aprendizaje, el tipo de aprendizaje que hay detrás de los algoritmos de DeepMind de Google para jugar al ajedrez (AlphaZero) y al Go (AlphaGo). La IA que utiliza RL lo que hace, básicamente, es usar datos para experimentar con diversas acciones. Las acciones generan diferentes recompensas y el algoritmo las emplea para reforzar aquellas acciones que den mejor resultado y reducir el valor (debilitar) aquellas acciones que den peor resultado. Cuando hablamos de aprendizaje algorítmico o de cómo aprende la IA nos referimos a cómo cambia la estructura interna (los valores que se asignan a las diferentes acciones) de los algoritmos en respuesta a su entorno. Se ha demostrado que este tipo de algoritmos en un entorno de decisión fijo, como por ejemplo cuando se utiliza la IA para organizar horarios o clasificar imágenes, se comportan muy bien en el sentido de que son capaces de generar reglas de decisión óptimas o cuasióptimas de manera rápida y autónoma (sin supervisión humana). Esto las hace especialmente atractivas a la hora de tomar decisiones rápidamente en entornos muy complejos.

Sin embargo, tenemos mucha menos información sobre el comportamiento de estos algoritmos en entornos dinámicos, como el que nos atañe. El problema de aprendizaje de un algoritmo en un contexto de interacción estratégica con otros algoritmos de aprendizaje es mucho más complejo. En nuestro caso, los algoritmos toman decisiones sobre precios que generan (o no) compras, y esto se traduce en beneficios que utiliza el algoritmo como recompensa para aprender. Al haber dos (o más) algoritmos aprendiendo a la vez en un juego donde las acciones de un participante afectan las recompensas del otro, el entorno se vuelve

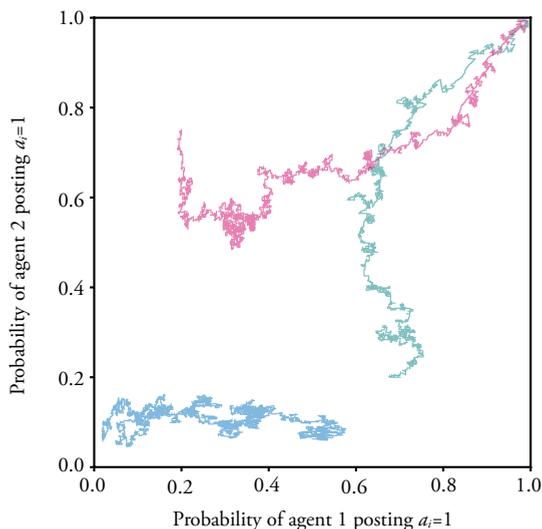
cambiante en el sentido de que las recompensas recibidas por los algoritmos cambia a la vez que los algoritmos modifican su estrategia (aprenden). En términos teóricos esto implica que el entorno se vuelve no-estacionario, lo que supone un problema a la hora de definir lo que significa una acción óptima. Lo que es óptimo en un momento dado puede dejar de serlo en el siguiente debido a que los algoritmos al aprender cambian su comportamiento y, por tanto, las recompensas que puedan recibir tanto ellos como sus contrincantes.

La mayor parte de lo que sabemos sobre el aprendizaje algorítmico en estos entornos se ha obtenido en base a estudios de simulaciones en los que se generan numerosas secuencias de interacciones entre algoritmos y se estudian las estadísticas obtenidas de las trayectorias de las estrategias de los algoritmos en cada simulación (como por ejemplo en Calvano *et al.*, 2020). En estas simulaciones el aprendizaje tiene un fuerte componente aleatorio lo que genera mucho ruido en las trayectorias, tal y como se ilustra en la [figura 1](#). En esta figura se describen las trayectorias de dos jugadores (algoritmos 1 y 2), en un juego simétrico de fijación de precios (DdP) en el que tienen que elegir entre dos acciones, a_1 y a_2 . En la abscisa de la [figura 1](#) tenemos la probabilidad de que el jugador 1 (el algoritmo 1) elija la acción $a_1 = C$ (y por lo tanto con la probabilidad complementaria elegirá la acción $a_2 = D$), y en la ordenada la probabilidad de que el segundo jugador (el algoritmo 2) elija la misma acción $a_1 = C$. Las tres trayectorias parten de diferentes puntos iniciales y nos dan una idea de cómo cambia la trayectoria en el tiempo.

Uno de los principales inconvenientes a la hora de analizar estas simulaciones es que para reducir la aleatoriedad en las trayectorias hay que hacer muchas simulaciones, y según

[Figura 1](#).

Simulación de tres trayectorias en un juego con dos acciones y dos jugadores



aumenta la complejidad de la interacción, la cantidad de simulaciones necesaria para obtener una muestra representativa puede volverse rápidamente impracticable. Un segundo inconveniente es que el incremento del tamaño de la muestra obliga a que el análisis se centre en propiedades estadísticas de la muestra y en tomar medias entre las trayectorias de la muestra. Estas trayectorias medias pueden ser muy poco representativas del comportamiento de las trayectorias de la muestra.

Desde el punto de vista teórico se han utilizado diferentes técnicas para aproximar la trayectoria que siguen los algoritmos y se han conseguido algunos resultados teóricos con diferentes versiones de algoritmos de aprendizaje con refuerzo (RL) bajo ciertas circunstancias. Los resultados principales se han obtenido en contextos donde la única información usada por los algoritmos es la recompensa recibida durante el juego. Cuando los algoritmos sólo utilizan sus recompensas del juego para aprender se puede construir de manera sencilla la probabilidad de transición de los parámetros de los algoritmos. Con esta probabilidad se puede computar una transición esperada como la solución a una ecuación diferencial ordinaria (EDO), y se puede demostrar que las trayectorias de los algoritmos se aproximan a la trayectoria descrita por la EDO (la transición esperada en tiempo continuo). El método general que se utiliza se denomina aproximación estocástica (*stochastic approximation, SA*).

Para entender mejor lo que sabemos teóricamente y describirlo de una manera más precisa, volvamos al ejemplo en la [figura 1](#). En esta figura podemos ver tres trayectorias. Estas trayectorias tienen dos componentes. Por un lado, hay un componente aleatorio que hace que la trayectoria cambie de manera no predecible. Es lo que hace que parezca que la trayectoria la haya dibujado alguien en un autobús en marcha. Por otro lado, hay un componente determinístico (estable) de la interacción esperada entre los algoritmos que le da dirección a la trayectoria. El método de SA consiste en utilizar una ecuación para describir el componente determinístico de la interacción esperada, y demostrar que la parte aleatoria deja de ser importante en ciertas circunstancias. Específicamente, la dinámica de los algoritmos se puede describir con la siguiente ecuación en diferencias:

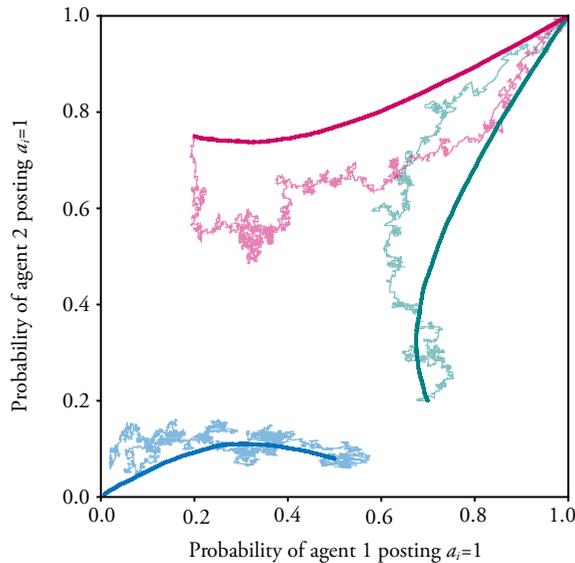
$$\theta_{n+1} = \theta_n + \gamma_{n+1} f(\theta_n, a_n), \quad [1]$$

donde θ_n corresponde al valor de los parámetros que describen el comportamiento de los algoritmos en la ronda n del juego, la función f describe el ajuste que hacen los algoritmos después de tomar las acciones a_n en la ronda n (y observar las recompensas que estas acciones generan), y γ_n que describe la velocidad de aprendizaje. La interpretación del parámetro γ es muy importante. Cuanto menor sea la velocidad γ , los parámetros de los algoritmos serán menos sensibles a lo que ocurre en cada ronda. Esto implica que para generar un cambio en los parámetros de una cierta magnitud, con una velocidad γ menor se necesitan más interacciones. En la [figura 2](#) hemos superimpuesto sobre la [figura 1](#) las trayectorias de los algoritmos con el mismo punto de inicio pero con una velocidad de aprendizaje γ mucho menor. Como se puede observar, el componente aleatorio apenas es visible a simple vista. Esto es debido a que la trayectoria acumula muchas interacciones pequeñas

que en media tienden a cancelarse, lo que reduce la importancia del componente aleatorio y deja a la vista el componente dinámico de las interacciones entre jugadores¹.

Figura 2.

Simulación de tres trayectorias en un juego con dos acciones



Este argumento que acabamos de proponer se puede formalizar de manera rigurosa. Usando técnicas de SA, se puede demostrar que al disminuir γ la trayectoria en tiempo discreto descrita por los algoritmos y por la ecuación [1] se aproxima a la trayectoria descrita por la siguiente ecuación diferencial ordinaria (en tiempo continuo):

$$\begin{aligned} \frac{d\theta}{dt} &= \dot{\theta} = F(\theta), \\ F(\theta) &= \mathbb{E}[f(\theta, a)], \end{aligned} \quad [2]$$

donde la esperanza se toma sobre la distribución de probabilidad sobre acciones de los algoritmos en la ronda n^2 .

En la figura 3 hemos superpuesto en gris una serie de trayectorias que describe la dinámica expresada por la ecuación [2] para el juego que estamos usando como ejemplo. Como

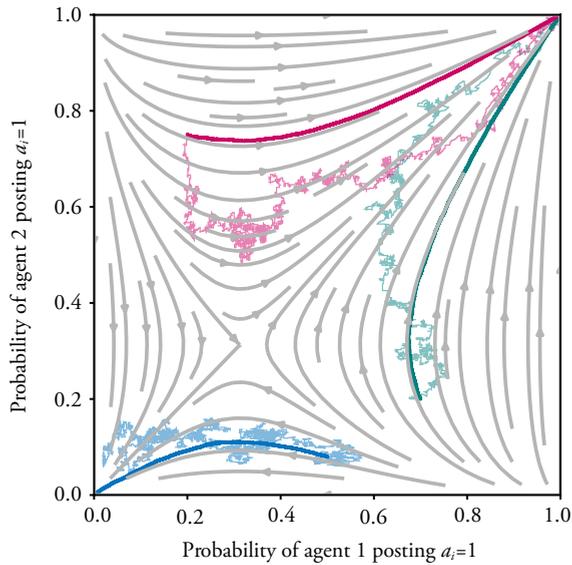
¹ Por otro lado, para simular la trayectoria descrita en la figura se han necesitado muchos más pasos que las de la figura anterior, donde la velocidad de aprendizaje γ era mucho mayor.

² Formalmente, θ define unas estrategias para cada uno de los agentes lo que genera la probabilidad conjunta sobre el espacio de acciones de los agentes, y es sobre esta probabilidad sobre la que se toma la esperanza.

podemos observar, las trayectorias de los algoritmos con una γ pequeña se comportan igual que las trayectorias expresadas por la ecuación [2].

Figura 3.

Simulación de tres trayectorias en un juego con dos acciones



La diferencia entre las ecuaciones [1, EDS] y [2, EDO] es que la primera (la EDS) tiene un componente aleatorio que la segunda (la EDO) no. Ambas se describen computacionalmente, pero la EDO, al no tener ningún componente aleatorio nos da varias ventajas. La primera es que para describir lo que se espera que ocurra desde un punto de inicio, basta con hacer una sola simulación. Con la EDS hay que hacer muchas para poder diferenciar el componente aleatorio del que no lo es. Además, la trayectoria que describe la EDO es única, mientras que cuando analizamos una muestra de las EDS hay que aplicar técnicas estadísticas para describir la muestra, y ello puede distorsionar los resultados. En concreto, el mapa de trayectorias descritas por la EDO nos indica que el espacio se puede clasificar en diferentes zonas en base a los puntos a los que tienden a converger las trayectorias (hacia la esquina superior derecha o la esquina inferior izquierda de la figura). En el caso de las trayectorias aleatorias, vemos que si tomásemos la media de trayectorias cerca del área de transición entre las dos zonas, estaríamos mezclando trayectorias con propiedades cualitativas muy distintas y su media nos daría resultados incompatibles con las propiedades fundamentales de la dinámica de la interacción entre los algoritmos. Una tercera ventaja es que el análisis numérico de las EDO se ha ido desarrollando mucho y existen técnicas muy eficientes y con características teóricas conocidas que nos permiten analizar las propiedades con mucha mayor rapidez y confianza que con las EDS. Y aunque la trayectoria de la EDS es esencialmente la misma que

la de la EDO cuando la γ es muy pequeña, el número de pasos necesarios para construir la trayectoria de la EDS es dos o más órdenes de magnitud mayor que la de la EDO, lo que supone un coste computacional mucho mayor.

En nuestro primer trabajo (Cartea *et al.*, 2022a) logramos integrar muchos resultados existentes en la literatura en el contexto de algoritmos que aprenden solamente en base a la recompensa recibida, establecer rigurosamente los resultados de aproximación para una gama muy amplia de algoritmos de aprendizaje, y demostrar que estos resultados de aproximación son válidos para casi todos los algoritmos de aprendizaje de RL y la interacción entre ellos, incluso si los algoritmos no son de la misma familia. Además, usando la EDO para describir la dinámica de los algoritmos en un juego de competencia (a la Bertrand) identificamos familias de algoritmos que convergen a los equilibrios de Nash del juego estático. Éstos, a pesar de la interacción repetida, no generan precios muy alejados de los precios competitivos. Por otro lado, dentro de la familia de algoritmos conocidos como *Q-learning algorithms* encontramos que algunos convergen a equilibrios de Nash del juego estático, mientras que otros pueden converger a acciones muy diferentes, y en concreto a equilibrios con precios significativamente por encima de los precios competitivos. Además, encontramos que los modelos clásicos de *Q-learning* pueden converger a equilibrios de acciones asimétricas, cuando el juego y los equilibrios de Nash son simétricos.

Una de las mayores limitaciones de los resultados que obtenemos en Cartea *et al.* (2022a) es que los algoritmos que estudiamos aprenden de una manera muy limitada. Sólo utilizan información de las recompensas recibidas en cada ronda del juego. La literatura que utiliza simulaciones ha estudiado algoritmos que además de la información sobre las recompensas, también incorporan información adicional, como por ejemplo qué acciones tomó cada uno de los participantes en la ronda anterior (por ejemplo, Calvano *et al.*, 2022). Nuestro segundo trabajo de investigación (Cartea *et al.*, 2022b) obtiene por primera vez resultados teóricos sobre qué tipo de ecuaciones ordinarias describen la trayectoria de los algoritmos que aprenden con información adicional, cuando esta información puede describirse utilizando estados.

Como ejemplo aplicamos la metodología al juego del prisionero repetido lo que nos permite hablar de colusión en precios. Los algoritmos en este segundo trabajo pueden incorporar información adicional, descritos como una señal privada que sólo ve un jugador (cada jugador i observa s^i), y una señal pública (todos los jugadores observan s). Además de la información que ya reciben de la recompensa obtenida en cada ronda. Por lo tanto, la dinámica de los (parámetros de los) algoritmos ya no se caracteriza con la ecuación [1] si no con una serie de ecuaciones como la siguiente que incluye más variables:

$$\theta_{n+1}^i(a | s^i, s) = \theta_n^i(a | s^i, s) + \gamma_{n+1} f_{a|s^i, s}^i(\theta_n, s_n, a_n, s_{n+1}) \quad [3]$$

La estructura es similar pero ahora tenemos un componente adicional que es s_n , un parámetro que recoge toda la información en las señales $\left(s, (s^i)_{i=1}^I\right)$.

No teníamos resultados teóricos sobre este tipo de algoritmos porque la metodología tradicional no puede resolver el problema que genera tener la información adicional recogida en la variable s . Si aplicamos la técnica de tomar la media como hicimos en la ecuación [3] nos queda la función: $\bar{f}_{a|s',s}^i(\theta_n, s_n)$ que no es determinística. Esta función incluye un componente aleatorio en su dependencia del estado, s_n .

La dependencia de la función \bar{f} del estado, s_n , genera un problema muy significativo desde el punto de vista teórico. En principio podríamos tomar la esperanza sobre s tal y como hacemos sobre las acciones, a . El problema es que para tomar esa esperanza habría que computar la medida sobre s y esa medida es muy difícil de computar. La dificultad estriba en la riqueza que aporta la variable s a los algoritmos. Cuando dejamos que los algoritmos condicionen su comportamiento en la información en s , permitimos una variedad mucho más amplia de comportamiento, pero a la vez generamos un problema. Al permitir que las acciones dependan de información adicional, y a su vez, permitir que esa información adicional incluya las acciones de los algoritmos, se genera un bucle de interacción entre información y acciones que complica el tomar expectativas. En concreto, para conseguir una versión de \bar{f} que sea determinística, en cada ronda tendríamos que reconstruir la medida sobre s_n paso por paso desde el estado inicial s_0 , seguido de las primeras acciones a_1 , después el estado resultante, s_1 , después las acciones siguientes a_2 , y así sucesivamente hasta llegar a la ronda n . Y en cada paso habría que tener en cuenta todas las posibles combinaciones. Esto es analítica y numéricamente impracticable.

Nosotros proponemos una solución: en lugar de utilizar la medida correcta, apliquemos la medida que se aplicaría en la ronda n si de ahí en adelante los algoritmos dejasen de aprender, $\Gamma_{\theta n}$. De esta manera tenemos una medida sencilla de construir que nos permite tomar la esperanza y obtener una función determinística:

$$F_{a|s',s}^i(\theta_n) = \mathbb{E}^{\Gamma_{\theta n}} \left[\bar{f}_{a|s',s}^i(\theta_n, s) \right] \sum_s \Gamma_{\theta n}(s) \bar{f}_{a|s',s}^i(\theta_n, s) \quad [4]$$

De esta manera podemos construir una función F que describe una ecuación diferencial ordinaria como la EDO anterior (donde obviamente este F será una función diferente del F que solamente utiliza información de la recompensa en nuestro trabajo anterior):

$$\dot{\theta} = F(\theta)$$

La parte más compleja de nuestro trabajo es demostrar que, a pesar de que la esperanza que estamos tomando en este segundo paso no es la correcta, las trayectorias de los algoritmos se aproximan, según γ se hace más pequeña, a las trayectorias de esta nueva EDO. La demostración se puede comprobar en *Cartea et al. (2022b)*.

Por lo tanto, hemos conseguido una herramienta que nos permite caracterizar las trayectorias de los algoritmos en un contexto más complejo que el existente anteriormente. Además, la ventaja de la EDO sobre la ecuación [3] es mucho mayor que la que hay entre la EDO y la ecuación [1], ya que el componente aleatorio en la ecuación [3] es mucho mayor. Las

ventajas de computación numérica, reducción a trayectorias determinísticas, y la eliminación de la agregación estadística de trayectorias suponen un gran avance. Y éste lo aplicamos al problema de competencia en el juego del prisionero.

4. COLUSIÓN TÁCITA Y CÁRTELES VIRTUALES

El DdP nos ofrece un modelo muy estilizado de la competencia en precios. Con nuestra investigación buscamos utilizar este modelo para entender cómo se comporta la IA, y si puede dar lugar a situaciones poco competitivas, e incluso a un comportamiento propio de acuerdos anticompetitivos (colusión tácita). En particular, nos centramos en el DdP repetido donde los contrincantes usan un tipo de algoritmo de aprendizaje concreto: *Q-learning*. Este algoritmo lo hemos elegido porque es un algoritmo muy representativo de los que se utilizan en la práctica y relativamente sencillo. Esencialmente, el algoritmo de aprendizaje fija unos pesos, que identificamos con la letra Q, para cada acción: $Q(C)$ y $Q(D)$. Cuando juega una acción a , por ejemplo $a = C$, el algoritmo actualiza el valor de $Q(C)$ pero no el de $Q(D)$, aumentándolo en relación al valor que obtiene después de haber tomado esa acción. Si siempre toma la acción con el valor de Q más alto nunca aprendería porque siempre estaría tomando la misma acción. Para evitar esto, el algoritmo "explora", es decir, prueba acciones que tienen valores de Q más bajos por si acaso podrían dar mejor resultado (y actualiza el valor de la acción que ha probado). La exploración permite al algoritmo ajustar los valores de Q para así aprender y elegir (con mayor probabilidad) la mejor acción.

En nuestro caso, y para incorporar el hecho que los algoritmos en la práctica usan información adicional además de las acciones que han tomado, aumentamos la información que recibe el algoritmo de *Q-learning* en el juego repetido. La literatura teórica que analiza algoritmos de *Q-learning* que actualizan sólo los pesos de las acciones ($Q(C)$ y $Q(D)$) en el DdP. Nosotros le damos más flexibilidad al algoritmo, permitiéndole tener pesos para C y para D diferentes, dependiendo de lo que haya pasado en la ronda anterior. Esto implica que hay cuatro pesos para la acción C : $C|CC$, $C|CD$, $C|DC$, y $C|DD$, donde $Q(C|CC)$ es el peso de la acción C si en la ronda anterior tanto un algoritmo como su oponente tomaron la acción C . Igualmente, la acción D también tiene cuatro pesos, uno por cada combinación de acciones pasadas. Formalmente, usamos la anotación a_i y a_j para referirnos a las acciones de los oponentes/algoritmos i y j , y el estado actual s_n lo describen las acciones de los dos participantes en la ronda anterior, en $n-1$ ($s_n = a_{n-1} = (a_{n-1}^1, a_{n-1}^2)$). En base a nuestros resultados construimos el sistema de ecuaciones (EDO) $\theta = F(\theta)$.

Este sistema está compuesto de una serie de ecuaciones que incluimos aquí para aquellos lectores que quieran saber exactamente cuáles son:

$$\begin{aligned} \dot{Q}^1(a|s) &= \Gamma_{\bar{Q}}(s) \pi_{\bar{Q}}^1(a|s) \sum_{a^2 \in A^2} \pi_{\bar{Q}}^2(a^2|s) \left(R^1(a, a^2) + \delta \max_{a'} \bar{Q}^1(a'|a, a^2) - \bar{Q}^1(a|s) \right), \\ \dot{Q}^2(a|s) &= \Gamma_{\bar{Q}}(s) \pi_{\bar{Q}}^2(a|s) \sum_{a^1 \in A^1} \pi_{\bar{Q}}^1(a^1|s) \left(R^2(a, a^1) + \delta \max_{a'} \bar{Q}^2(a'|a^1, a) - \bar{Q}^2(a|s) \right). \end{aligned} \quad [5]$$

Estas dos ecuaciones tienen cuatro versiones por cada una de las diferentes combinaciones de $s = ((CC), (CD), (DC), (DD))$ multiplicadas por las dos posibles acciones, $a \in \{C, D\}$. En total tenemos $2 \text{ por } 4 \text{ por } 2 = 16 \text{ ecuaciones}$.

Desde cualquier punto de partida (descrito por los parámetros $(Q_0^i(a|s))$) donde iniciemos los algoritmos, estas ecuaciones (las EDO) nos describen cómo evolucionan los algoritmos, y por consiguiente cómo aprenden y qué es lo que acaban aprendiendo a hacer. En particular, lo que nos importa saber es la estrategia de los algoritmos y el resultado de la interacción de las estrategias. Para facilitar la visualización de los resultados vamos a reducir el número de ecuaciones imponiendo supuestos de simetría, y en lugar de centrarnos en los parámetros Q^i nos centramos en la probabilidad de cada acción condicional a cada estado que estos parámetros generan: $\pi_{Q(n)}^i(a|s)$, o más sencillamente, $\pi_n^i(a|s)$. En primer lugar, aprovechamos que $\pi_n^i(D|s) = 1 - \pi_n^i(C|s)$ para reducir el número de ecuaciones a la mitad. Después asumimos simetría entre los dos algoritmos: $Q_0^1(a|s) = Q_0^2(a|s)$, lo que implica que $\pi_0^1(a|s) = \pi_0^2(a|s)$. Y por último, reducimos el número de ecuaciones relevantes a tres asumiendo simetría en las desviaciones unilaterales: $Q^i(D|(DC)) = Q^i(D|(CD))$, lo que implica que $\pi_n^1(a|CD) = \pi_n^2(a|DC)$. Con estos supuestos el número de estados y ecuaciones que necesitamos para describir el sistema completo son tres: cooperación (C C), desvío unilateral (C D) o (D C), y competencia/castigo (D D). Asociados a estos estados tenemos las dos variables que nos importan: la estrategia de los algoritmos, descrita con la variable $\pi_n(C|s)$ que nos dice la probabilidad de tomar la acción C (cooperar/precio alto) si el algoritmo recibe la información: el estado es s (dados los parámetros Q), y el resultado de la interacción de estas estrategias, $\Gamma_{Q(n)}(s)$, que nos dice dadas estas estrategias, cuál es la probabilidad de que el estado resultante sea s (si los algoritmos dejan de aprender y por lo tanto los parámetros se quedan en Q_n y $\pi_t^i(a|s) = \pi_n^i(a|s)$ para cualquier $t \geq n$).

Para visualizar lo que nos permite nuestra metodología vamos a considerar dos puntos de partida diferentes y ver lo que hacen los algoritmos. Los resultados aparecen en las **figuras 4 y 5**. Los parámetros iniciales son (A) **figura 4**: $\pi_{C|CC}^0 = 0,8$, $\pi_{C|DD}^0 = 0,4$ y $\pi_{C|CD}^0 = 0,5$ y (B) **figura 5**: $\pi_{C|CC}^0 = 0,7$, $\pi_{C|DD}^0 = 0,7$ y $\pi_{C|CD}^0 = 0,5$.

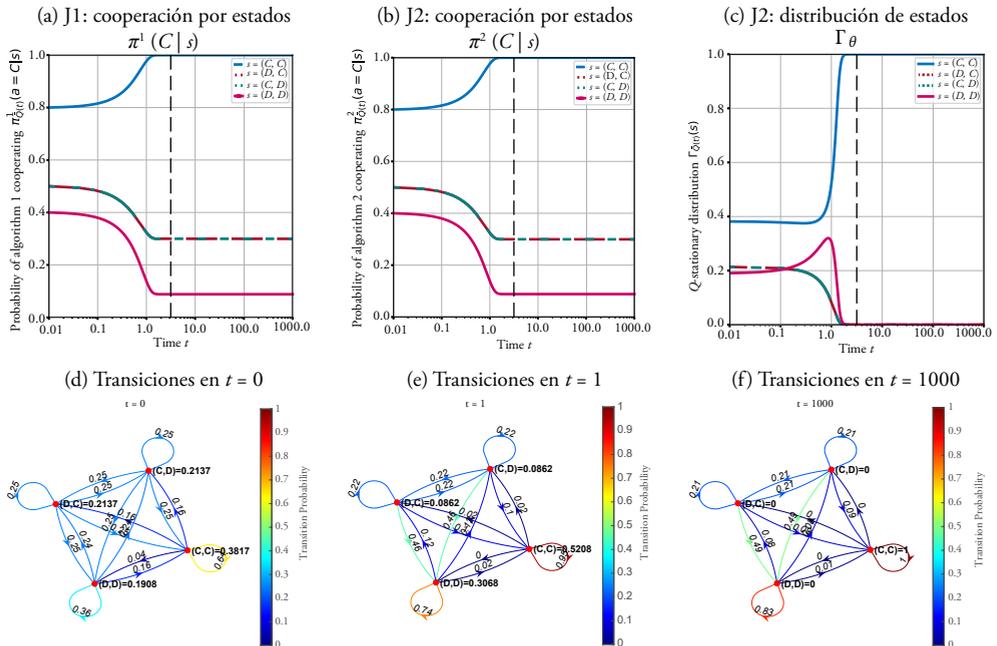
Las dos figuras reflejan el comportamiento de los algoritmos a lo largo del tiempo (en escala logarítmica). Las figuras están divididas en seis paneles. En los paneles (a) y (b) encontramos las estrategias, la probabilidad de cooperar. Las diferentes líneas describen la probabilidad de cooperar dependiendo de la información recibida. Si reciben la información (C C), es decir que en la última ronda ambos cooperaron, la probabilidad de volver a cooperar la recoge la línea continua azul. La línea rosa describe la probabilidad de cooperar si reciben la información (D D), y las líneas intermitentes las probabilidades de cooperar si uno de los dos tomó la acción C y el otro la D. En el panel (C) tenemos las consecuencias de la interacción de esas estrategias: la probabilidad de los estados (C C) en azul, (D D) en rosa, y (C D) o (D C) la línea intermitente. En la **figura 4** podemos ver cómo los dos jugadores empiezan (para $t < 0,01$) mezclando la decisión entre precios altos (C) y bajos (D) dependiendo del estado: precios altos (C) con probabilidad 0.8 si los precios han sido altos (C C), con probabilidad 0.4 si los precios habían sido bajos (D D), y con probabilidad 0.5 si uno había ofertado precio alto y el

otro bajo. Según va pasando el tiempo vemos que las líneas intermitente y rosa bajan, lo que implica que disminuye la probabilidad de un precio alto (C) y por consiguiente aumenta la de un precio bajo (D) –los algoritmos “aprenden a penalizar” tanto si es una desviación unilateral (se observe C,D o D,C)– la línea intermitente, o si ya estaban penalizando (D D), pero sin llegar al extremo de penalizar con probabilidad uno. El resultado de esto lo vemos en el panel 4c donde la probabilidad de observar cooperación/precios altos (C C) se mantiene estable, pero aumenta la probabilidad de observar competencia (D D-la línea rosa aumenta entre $t = 0$ y $t = 1$). Pero, llega un momento en que los algoritmos empiezan a cooperar con mayor frecuencia, la línea azul sube hasta llegar al punto donde en el panel 4c la probabilidad de (C C) llega a uno y las demás líneas bajan a cero –los algoritmos sólo están ofertando precios altos. En los paneles 4a y 4b vemos que los algoritmos han aprendido una estrategia que les lleva a fijar precios altos si observan precios altos (C C), pero castigan con una probabilidad alta cualquier desviación, con estrategias que dan una probabilidad baja a cooperar si los estados son (C D), (D C) o (D D).

En los paneles inferiores, las figuras 4d-4f describen las probabilidades de transición entre estados condicional en el estado de partida, en diferentes momentos en el tiempo (inicialmente $t = 0$, en un punto intermedio $t = 1$, y cuando ya ha aprendido y los parámetros no cambian $t = 1000$). Al principio (figura 4d) hay mucho movimiento entre estados. En el

Figura 4.

Ejemplo de colusión (A)



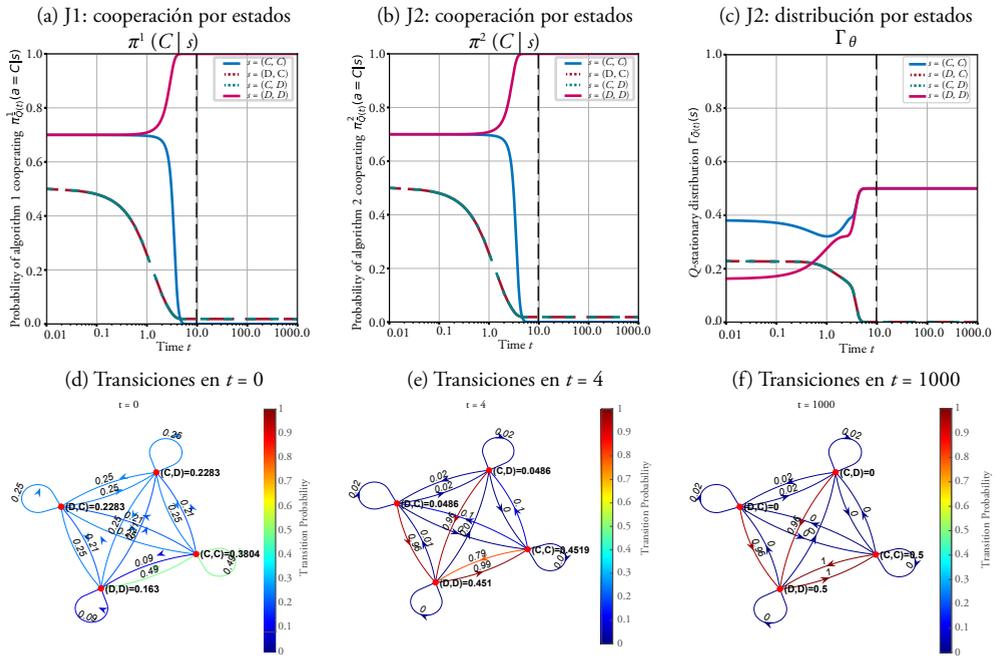
paso intermedio (figura 4e) vemos que las transiciones están concentradas en quedarse en (C C) o en transicionar a (D D). Este patrón es el que acaban aprendiendo los algoritmos, pero evitando la transición a (D D) y quedándose en (C C).

En resumen, vemos cómo los algoritmos “aprenden” a mantener precios altos bajo la “amenaza” de pasar un tiempo significativo en una guerra de precios bajos (en D,D). Esto es un patrón de comportamiento tradicionalmente descrito como colusión tácita: los participantes sostienen precios altos con una estrategia de PC sin comunicarse entre ellos. Esto es especialmente sorprendente, ya que los algoritmos además de encontrar una acción que les beneficia a ambos, además consiguen coordinarse para penalizar al otro si el otro no se comporta correctamente.

En la figura 5 encontramos un comportamiento diferente, a raíz de un punto de partida diferente. La estructura de los paneles es la misma que la anterior por lo que empezamos con las estrategias iniciales de ambos jugadores en los paneles 5a y 5b. Al principio, ambos jugadores cooperan con una probabilidad elevada (0.75) si ambos toman la misma acción, tanto en precios altos (C C) o en precios bajos (D D). Por otro lado, si se observa una desviación unilateral se empieza cooperando con probabilidad 0.5, pero enseguida esta probabilidad empieza a disminuir. En el panel 5c vemos que en este momento inicial los algoritmos van cambiando de estado sin quedarse mucho tiempo en ninguno de ellos, aunque, como vemos en el panel 5d

Figura 5.

Ejemplo de coordinación (B)



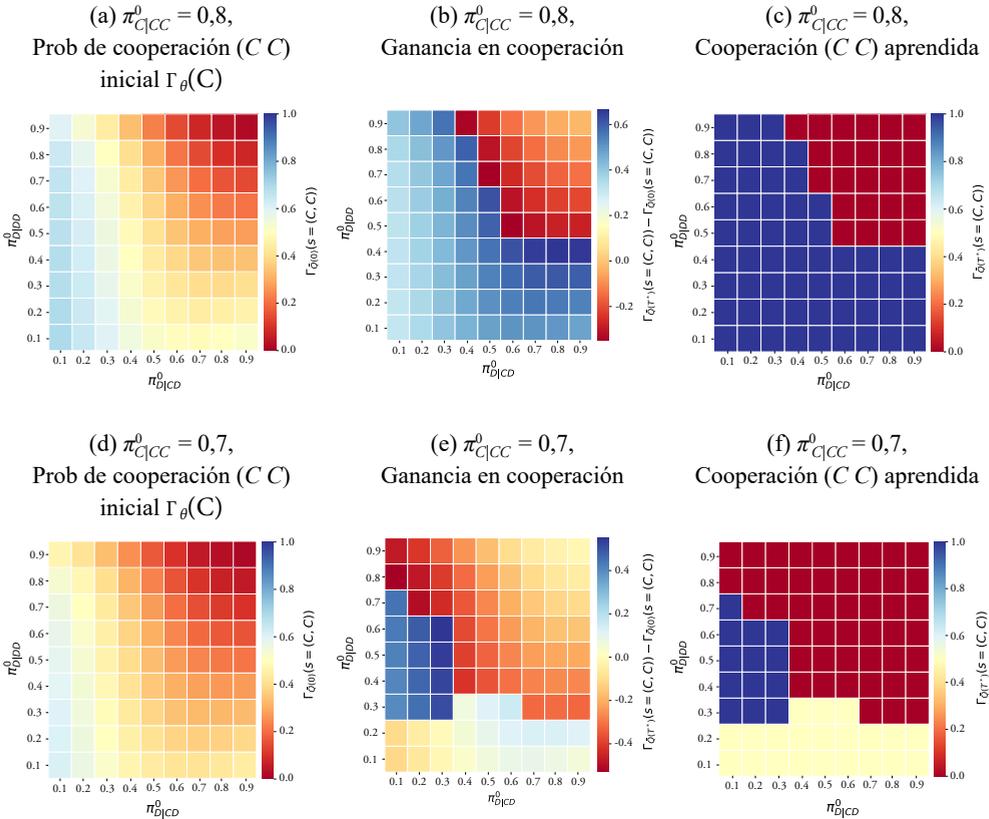
la tendencia es a estar en $(C C)$ y retornar allí desde $(D D)$ cuando hay desviaciones. Según pasa el tiempo y los algoritmos aumentan la penalización por desviaciones unilaterales los algoritmos empiezan a reforzar esta transición a $(C C)$ desde $(D D)$ en respuesta a cualquier desviación, aunque a su vez, también observamos que se refuerza la transición de $(C C)$ a $(D D)$. Esto provoca un cambio en la dinámica que observamos en los paneles panel 5a-panel 5c y panel 5f. Los algoritmos “aprenden” a responder con precios bajos con probabilidad uno cuando ambos juegan $(C C)$, mientras que en cuanto ambos juegan $(D D)$ responden con precios altos con probabilidad uno, mientras que cualquier desviación unilateral se responde con precios bajos. El resultado final es que los algoritmos entran en un bucle de alternancia entre precios altos y bajos. Ambos se coordinan en un comportamiento cíclico, que alterna precios altos un día con precios bajos el siguiente. Este tipo de comportamiento se había observado en simulaciones pero existían dudas sobre si esto es un fenómeno común o no.

Hemos visto dos ejemplos. En uno los algoritmos aprenden a sostener colusión de una manera tácita, en el segundo aprenden a coordinarse en un comportamiento cíclico. Esto nos lleva a preguntarnos, ¿cuál es el comportamiento general que deberíamos observar de estos algoritmos?, ¿se coordinan?, ¿cooperan?, ¿coluden? Para contestar a estas preguntas, en la [figura 6](#) exploramos lo que ocurre cambiando los parámetros de inicio. En la fila superior, paneles 6a a 6c, estudiamos lo que ocurre cuando empezamos con una probabilidad de cooperar de 0.8 después de observar cooperación, $\pi_{C|CC}^0 = 0,8$, si variamos la probabilidad de desviarse (D) después de observar los otros estados: $(D D)$ en la ordenada y $(D C)$ en la abscisa. Estas probabilidades las variamos de 0.1 a 0.9, lo que nos genera una malla de 81 valores iniciales, cada cuadrado coloreado de estas figuras corresponde a una combinación de parámetros iniciales diferente. En la fila inferior, paneles 6d a 6f, estudiamos lo mismo pero partiendo de una probabilidad de cooperación tras observar $(C C)$ igual a 0.7. En total analizamos 162 parámetros iniciales que nos dan una idea de cuán representativos son nuestros dos ejemplos.

Los paneles 6a y 6d describen el punto de partida: la probabilidad que las estrategias iniciales de ambos den lugar a precios altos $(C C)$, $\Gamma_0(CC)$. En ambos casos esta probabilidad es inicialmente alta (azul-colores fríos) solo si la probabilidad de precios bajos (D) es baja (y la complementaria, la de precios alta, C , es alta) –en la esquina inferior izquierda. Los paneles 6c y 6f describen el punto final: la probabilidad de que las estrategias que ambos aprenden den lugar a precios altos $(C C)$, $\Gamma_T * (CC)$. En el panel 6c vemos que el espacio se divide en dos: en rojo aprenden precios competitivos, y en azul precios de colusión. Esto nos indica que los valores iniciales son importantes a la hora de predecir lo que van a hacer los algoritmos. Cuando los parámetros iniciales tienden a ofrecer precios altos, es muy probable que los algoritmos acaben en $(C C)$, mientras que si tienden a ofrecer precios competitivos, es más probable que los algoritmos acaben ofreciendo precios competitivos, $(D D)$. Sin embargo, en el panel 6f aparece un tercer color, el blanco. Para estos parámetros iniciales los algoritmos no acaban ni en $(C C)$ ni en $(D D)$. Lo que observamos es que aprenden a alternarse tal y como vimos en el ejemplo B. Con esto vemos que los algoritmos pueden coordinarse en ciclos y no es un comportamiento inusual, sino que ocurre de manera robusta para un número significativo de parámetros iniciales.

Figura 6.

Espacio de cooperación



Los paneles intermedios 6b y 6e describen el cambio en la probabilidad de ofrecer precios altos ($\Gamma_T * (CC) - \Gamma_0(CC)$). Colores claros, cercanos al blanco, indican que esta probabilidad cambia poco, y los encontramos en las esquinas superior derecha e inferior izquierda, así como en la zona correspondiente al aprendizaje de ciclos. Estos colores claros indican que los algoritmos no cambian mucho su comportamiento y sugiere que los algoritmos empiezan con cierto comportamiento y éste se hace permanente. Es como si se coordinasen para quedarse como empezaron. En cambio, hay grupos de parámetros iniciales, sobre todo alrededor de las zonas de transición de un color a otro (en los paneles 6c y 6f), donde observamos grandes cambios entre el comportamiento observado inicialmente y el observado cuando los algoritmos se estabilizan.

Para analizar en más detalle lo que pasa en estas zonas de grandes cambios miramos cómo cambia el comportamiento de los algoritmos en base a los cambios que observamos en las estrategias, recogidos en la figura 7. Para facilitar la transición entre la figura 6 y la 7 repetimos los paneles 6c y 6f en los paneles 7a y 7d. Éstos los completamos con los paneles 7b y 7e

donde capturamos el cambio en el comportamiento cuando se observa una desviación unilateral, cuando $s=(CD)$ or (DC) , y en concreto, miramos como cambia la probabilidad de ofrecer precios bajos, que denominamos el castigo inmediato, $\pi(D|(CD))$. Lo que observamos en nuestra muestra de parámetros es que los algoritmos tienden a incrementar esta probabilidad de castigo, sobre todo cuando ésta es inicialmente baja. La mayor variación la encontramos en los valores de inicio intermedios, en las zonas de transición entre diferentes áreas coloreadas en los paneles 7a y 7d. En el panel 7b vemos cómo esta probabilidad de castigo inmediato aumenta (se vuelve azul) a ambos lados de la línea que separa los parámetros que llevan a (CC) o a (DD) para valores intermedios de las probabilidades de castigo. En el panel 7c donde se reflejan los cambios en la probabilidad de precios bajos después de observar (DD) , lo que llamamos la duración del castigo, podemos observar un patrón similar: la mayor variación la encontramos en los valores de inicio intermedios, y en las zonas de transición entre diferentes áreas coloreadas en los paneles 7c y 7f. En el panel 7c la duración del castigo también aumenta (se vuelve azul) a ambos lados de la línea que separa los parámetros que llevan a (CC) o a (DD) especialmente para los valores iniciales intermedios, y observamos una gran diferencia en la ganancia de la duración del castigo (el cambio en la duración del castigo) a ambos lados de la zona donde acaban alternándose entre (CC) y (DD) , y las otras zonas.

Estos cambios en las estrategias de los algoritmos las interpretamos de la siguiente manera: en primer lugar diferenciamos tres áreas: (i) la de precios altos (CC) , (ii) la de precios bajos, (DD) , y (iii) la de alternancia. En segundo lugar observamos que en las estrategias que tienen una tendencia inicial fuerte hacia áreas (i) o (ii), las estrategias varían poco (colores rojos y rojizos). Esto lo interpretamos como un comportamiento de coordinación entre algoritmos sobre valores iniciales. En tercer lugar observamos importantes cambios en las zonas de transición entre las áreas. En estas zonas el comportamiento lo entendemos como aprendido. Los algoritmos se adaptan hacia un comportamiento u otro. Esta adaptación se centra en un aumento de la estrategia de castigo: aumento tanto del castigo inmediato como la duración de castigo. Esta adaptación puede tener dos consecuencias: si el castigo es adecuado, ayuda a sostener precios altos, pero por el otro lado, si el castigo es demasiado duro éste empuja a los algoritmos a precios bajos. Por lo tanto, para parámetros donde no hay una tendencia clara hacia un lado u otro, los algoritmos endurecen los castigos y esto puede dar lugar a dos situaciones: colusión tácita o guerra de precios.

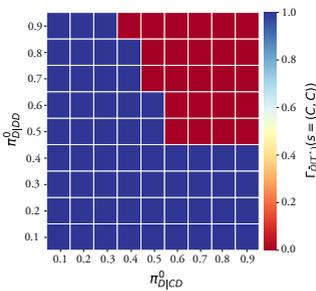
Por lo tanto, con la metodología que hemos desarrollado podemos analizar en detalle cómo se comportan los algoritmos que compiten entre sí. Hemos visto en un contexto estilizado del DdP las políticas de precios que implementan los algoritmos de *Q-learning*. En particular, hemos visto que los algoritmos tienden a mantener y reforzar su comportamiento inicial, si sus parámetros iniciales son similares a los de uno de los tres comportamientos que observamos en el límite: sostener precios altos (CC) , precios bajos (DD) , o alternar entre uno y otro en un ciclo determinístico. Con estos parámetros iniciales, el comportamiento que percibimos lo interpretamos como acomodación y/o coordinación a los parámetros iniciales. Por otro lado, analizamos que para parámetros iniciales sin una tendencia inicial clara hacia uno de estos tres comportamientos, lo que observamos es que los algoritmos tienden a aumentar las estrategias de bajar precios y que esto puede dar lugar a dos tipos de comportamiento.

Por un lado, esta bajada de precios puede dar lugar a una guerra de precios que lleva a los algoritmos a jugar (DD). Por otro lado, si la estrategia de penalización implícita en la bajada de precios no es demasiado agresiva, los algoritmos acaban replicando comportamiento de colusión tácita: sostienen precios altos bajo una amenaza de penalización sustancial en respuesta a bajadas de precio.

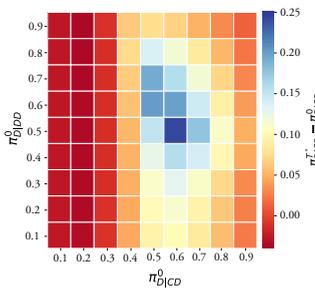
Figura 7.

Cooperación y castigo

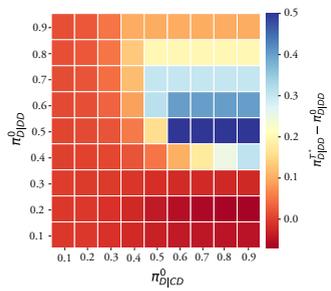
(a) $\pi_{C|CC}^0 = 0,8$,
Cooperación ($C C$) aprendida
 $\Gamma_T * (C)$



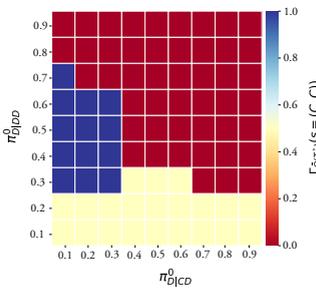
(b) $\pi_{C|CC}^0 = 0,8$,
Ganancia de castigo inmediato
 $\Delta * \pi (D|CD)$



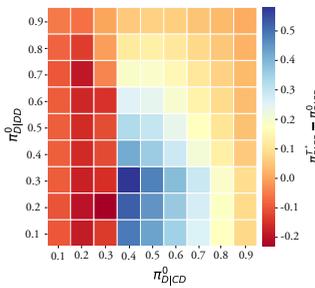
(c) $\pi_{C|CC}^0 = 0,8$,
Ganancia en duración de castigo
 $\Delta * \pi (D|DD)$



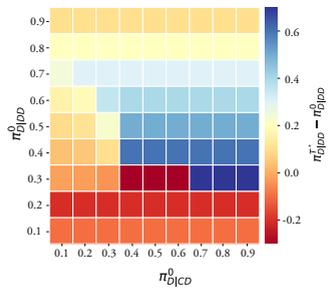
(d) $\pi_{C|CC}^0 = 0,7$,
Cooperación ($C C$) aprendida
 $\Gamma_T * (C)$



(e) $\pi_{C|CC}^0 = 0,7$,
Ganancia de castigo inmediato
 $\Delta * \pi (D|CD)$



(f) $\pi_{C|CC}^0 = 0,7$,
Ganancia en duración de castigo
 $\Delta * \pi (D|DD)$



5. LA IA: NUEVOS DESAFÍOS PARA LAS AUTORIDADES DE COMPETENCIA

Nuestros resultados en el contexto limitado del juego del DdP con dos algoritmos de Q -learning compitiendo entre sí sugieren que las autoridades de la competencia se enfrentan a nuevos desafíos, ya que la IA puede generar comportamientos poco competitivos, con las características propias de colusión, pero sin generar las señales que se utilizan hoy en día para perseguir casos de colusión.

Primero, hemos visto que los algoritmos, partiendo de ciertos parámetros iniciales, cambian de estrategia ($\pi(a|s)$) y de comportamiento ($\Gamma(s)$) de una manera que es consistente con el aprendizaje de estrategias de colusión. Para intentar aproximarnos a las implicaciones de estos resultados, sigamos la propuesta de Maureen Ohlhausen de la Federal Trade Commission y sustituyamos el término “algoritmo” por la frase “un tipo llamado Pepe”. ¿Qué supone que dos tipos llamados Pepe ajusten sus estrategias de tal manera que ofrezcan precios altos bajo la amenaza de castigo con precios más competitivos en respuesta a una reducción de precios unilateral? La regulación de competencia tradicional llama a este tipo de comportamiento colusión tácita. Pero, la aplicación de la legislación vigente a estos dos tipos llamados Pepe suele requerir algún tipo de pruebas de comunicación entre ellos. En el caso de algoritmos no podemos quedarnos en la perspectiva humana y hemos de dejar de hablar de tipos llamados Pepe y hablar de algoritmos. Es difícil argumentar que los algoritmos estén comunicándose ya que hemos visto que no lo necesitan. Si partimos de una perspectiva humana exclusiva, la autoridad de la competencia no puede perseguir esta situación de comportamiento de colusión tácita de libro que encontramos. La colusión tácita está clara y es claramente demostrable, ya que se puede acceder a los parámetros de comportamiento de la IA, pero esta colusión tácita se establece en un contexto de falta de comunicación igualmente demostrable.

El segundo desafío viene de determinar cómo han llegado los algoritmos a la situación de comportamiento colusivo, una pregunta que ni siquiera se plantea cuando hablamos de colusión entre humanos. Hemos determinado que una elección estratégica de los parámetros iniciales puede colocar a los algoritmos en unas trayectorias con una tendencia muy fuerte a generar un comportamiento u otro. Las autoridades se enfrentan a una nueva situación donde los humanos interactúan en un metajuego estratégico de selección de los valores iniciales de los parámetros con los que los algoritmos arrancan. Es ahí donde se ha de buscar la intencionalidad que está ausente del comportamiento mecánico de los algoritmos. El desafío está en qué criterios establecer para determinar hasta qué punto ciertos parámetros iniciales se pueden considerar causantes de una situación de colusión tácita o no.

Un tercer desafío surge de la práctica del uso de la IA. La situación descrita aquí, en la que se implementan los algoritmos con unos parámetros iniciales y se les deja actuar hasta el final, no es común en la práctica. Lo normal es que los algoritmos se desarrollen previamente, se implementen, y una vez en funcionamiento, éstos estén supervisados por humanos que de vez en cuando intervienen para ajustar diferentes parámetros de los algoritmos. Estas decisiones se toman para mejorar el funcionamiento de los algoritmos, que es establecer precios que generan mayores beneficios. Está claro que la selección de parámetros que llevan a los algoritmos a aprender a coludir son los más rentables y por lo tanto los que acabarán siendo seleccionados. El desafío estriba en que la ley no obliga a competir, lo que hace imposible castigar este tipo de comportamiento si no hay comunicación entre las empresas (y por lo tanto una conspiración para no competir). ¿Hasta qué punto puede o debe la autoridad de la competencia establecer un criterio que determine que los precios de los algoritmos son demasiado altos y que las empresas están obligadas a intervenir para corregir el comportamiento de estos algoritmos?

No vamos hacia el futuro que previó Phillip K. Dick donde los replicantes se hacen humanos, si no hacia uno donde la IA replica comportamientos desde una lógica propia. Esta lógica nos obliga a replantear qué es y cómo se defiende la competencia, ya que parece que la IA a veces sueña con sus propios cárteles virtuales.

Referencias

- ASSAD, S., CLARK, R., ERSHOV, D. y XU, L. (2020). Algorithmic pricing and competition: Empirical evidence from the German retail gasoline market. *CESifo Working Paper*; Na. 8521.
- CALVANO, E., CALZOLARI, G., DENICOLO, V. y PASTORELLO, S. (2020). Artificial intelligence, algorithmic pricing, and collusion. *American Economic Review*, 110(10), pp. 3267-97.
- CARTEA, Á., CHANG, P. y PENALVA, J. (2022). *Algorithmic Collusion in Electronic Markets: The Impact of Tick Size*. Available at SSRN 41 5954.
- CARTEA, Á., CHANG P., PENALVA J. y WALDON, H. (2022). *The Algorithmic Learning Equations: Evolving Strategies in Dynamic Games*. Available at SSRN 4175239.
- COMPETITION & MARKETS AUTHORITY. (2018). Pricing Algorithms. Available at <https://www.gov.uk/government/publications/pricing-algorithms-research-collusion-and-personalised-pricing>
- COMPETITION & MARKETS AUTHORITY. (2021). Algorithms: How they can reduce competition and harm consumers. Available at <https://www.gov.uk/government/publications/algorithms-how-they-can-reduce-competition-and-harm-consumers>
- EUROPEAN COMMISSION. (2017). Algorithms and Competition. Speech by Commissioner Margrethe Vestager at Bundeskartellamt 18th Conference on Competition, Berlin.
- HARRINGTON, J. E. (2018). Developing competition law for collusion by autonomous artificial agents. *Journal of Competition Law & Economics*, 14(3), pp. 331-363.
- OECD. (2017). Algorithms and Collusion: Competition Policy in the Digital Age. Available at <https://www.oecd.org/competition/algorithms-collusion-competition-policy-in-the-digital-age.htm>
- OHLHAUSEN, M. K. (2017). Should We Fear The Things That Go Beep In the Night? Some Initial Thoughts on the Intersection of Antitrust Law and Algorithmic Pricing. Remarks from the Concurrences Antitrust in the Financial Sector Conference. New York, NY. May 23, 2017.

CAPÍTULO IX

Diferencias de género en la investigación económica. Un enfoque de aprendizaje automático

J. Ignacio Conde-Ruiz
Juan-José Ganuza
Manu García
Luis A. Puch

Utilizando técnicas de aprendizaje automático no supervisado y una nueva base de datos compuesta por los resúmenes de todos los artículos publicados en revistas *Top5* (T5) de economía para el periodo (2002-2019), se demuestra que existen diferencias horizontales persistentes y significativas en la forma en que hombres y mujeres abordan la investigación en economía. Utilizando el modelo temático estructural (*STM*) se estiman los temas de investigación de los artículos, y se asignan los artículos (y los autores) a dichos temas. La distribución resultante de temas de investigación por sexo demuestra que hay diferencias horizontales significativas de género en la elección de temas de investigación. Estos resultados son importantes por varias razones: i) las publicaciones de T5 son clave para la carrera investigadora y también para determinar la trayectoria de la investigación económica; ii) los resultados son robustos en el sentido de que se generan automáticamente con un modelo probabilístico sin ninguna asignación arbitraria de los trabajos a categorías o campos de investigación preestablecidos; iii) por último, los recientes resultados teóricos de Conde-Ruiz y Ganuza (2017); Conde-Ruiz *et al.* (2022) y Siniscalchi y Veronesi (2020) muestran que las diferencias “horizontales” de género en la elección del tema de investigación pueden conducir a una brecha de género permanente.

Palabras clave: brecha de género, aprendizaje automático, estimación de temas latentes, revistas de gran impacto en economía.

1. INTRODUCCIÓN

La economía digital ha venido acompañada por una gran capacidad de generar, analizar y gestionar gran cantidad de datos. En el pasado, se usaban complejas técnicas econométricas para resolver problemas de inferencia con bases de datos muy limitadas. En el nuevo paradigma, la idea es utilizar la capacidad computacional de algoritmos de inteligencia artificial para explotar ricas bases de datos, con modelos probabilísticos relativamente sencillos. Esto permite obtener unos resultados empíricos que son robustos en una dimensión particular, provienen de algoritmos sin hipótesis o intervención humana que *a priori* condicionen dichos resultados obtenidos.

En este capítulo vamos a presentar un análisis empírico llevado a cabo en (2022) que tiene estas características. El objeto del análisis es identificar diferencias de género en la elección de temas de investigación en economía y finanzas. Esta pregunta ha sido analizada con anterioridad utilizando los códigos JEL (*Journal of Economic Literature*) que los propios autores elijen para describir sus artículos o las áreas de conocimiento de los departamentos de economía. Esta metodología depende de un juicio subjetivo humano y además son frecuentemente descripciones poco precisas del objeto de la investigación. Por el contrario, Conde-Ruiz *et al.* (2022) utiliza un enfoque de aprendizaje automático no supervisado que tiene las siguientes ventajas. En primer lugar, analiza todos los artículos publicados en las mejores revistas de economía, las denominadas *Top-five*, T5, entre 2002-2019. Esta es una gran base de datos, cuyo análisis de textos sólo se ha hecho factible con el desarrollo de estas nuevas herramientas de inteligencia artificial. En segundo lugar, no se introduce ninguna guía sobre el contenido de los temas de investigación. El algoritmo sin ningún tipo de supervisión e intervención humana determina cuál es el conjunto de temas que mejor se adapta a los datos. El algoritmo también asigna los artículos a los diferentes temas de investigación. Una vez asignados el artículo (y sus autores) a los diferentes temas estimados, se puede analizar si los autores masculinos y femeninos presentan una distribución entre los temas de investigación diferente. Este último paso tampoco es trivial, dado que el género no es observable directamente. De nuevo, los algoritmos resuelven este problema, comparando los nombres de pila de los autores con grandes bases de datos que relacionan nombres de pila y género. El algoritmo estima una probabilidad de que el sexo esté bien asignado, reduciendo la intervención humana a un conjunto muy pequeño de autores donde esta probabilidad es significativamente diferente de 1.

El capítulo comienza con la motivación de la pregunta de investigación. ¿Por qué es importante identificar diferencias horizontales de género en la elección de temas de investigación? Recientes artículos de investigación muestran mecanismos teóricos por los que las diferencias horizontales (que no afectan a la calidad o la productividad) se trasladan a discriminación y brechas de género. También, se documenta la existencia de esta brecha de género en numerosos sectores de actividad económica y específicamente, en las carreras académicas en las áreas de economía y finanzas.

La tercera sección explica en detalle la metodología seguida. La construcción de la base de datos y su preparación para el análisis de textos. Se explica la elección del mecanismo de aprendizaje automático utilizado (*STM, Structural Topic Model*) y su funcionamiento. La sección cuarta presenta el análisis de textos llevado a cabo en Conde-Ruiz *et al.* (2022) donde se presentan los temas de investigación estimados y la distribución de artículos, autores y género sobre ellos. El principal resultado que se obtiene es que las distribuciones de hombres y mujeres sobre los temas de investigación difieren significativamente. La única variable que se introduce al algoritmo es el número de temas a investigar. En el análisis principal se estiman 54 temas, que es el número que mejor se adapta al conjunto de datos (artículos). Mientras que esta es la estrategia adecuada para ver si difieren hombres y mujeres en la distribución de los temas de investigación, tiene el inconveniente de que no siempre es fácil interpretar semánticamente dichos temas. En la sección quinta, se fuerza al algoritmo a estimar 15 temas, lo que permite relacionar mejor los temas con las áreas tradicionales de investigación. Gracias a ello, podemos analizar específicamente el campo de las finanzas, y demostrar que la importancia de este campo en las T5 ha aumentado, pero esto no ha llevado a reducir la poca representación de las mujeres en esta área de investigación. Por último, la sección sexta presenta las conclusiones.

2. BRECHAS DE GÉNERO EN PROMOCIONES PROFESIONALES, DIFERENCIAS HORIZONTALES Y COMITÉS

La discriminación ocurre cuando algunos trabajadores son tratados de manera diferente a otros por sus características personales, tales como género, raza, edad, nacionalidad, orientación sexual, etc., que no están relacionadas con su productividad (Arrow, 1973). La discriminación no sólo conduce a una mayor desigualdad y falta de equidad, también puede generar pérdidas de eficiencia: pérdida de talento, falta de incentivos para invertir en capital humano por parte del grupo discriminado e ineficiente asignación de recursos.

En este capítulo vamos a centrarnos específicamente en la discriminación por razones de género. Observamos brechas de género en el desarrollo profesional en muchos ámbitos. Brechas de género que existen a pesar de los esfuerzos realizados por toda la sociedad para luchar contra la discriminación en las últimas décadas. Gracias a estos avances, gran parte de las barreras y mecanismos de discriminación directa y explícita, han sido eliminados o reducidos. Sin embargo, la brecha de género todavía persiste; por ejemplo, la diferencia salarial es del 17 % sin tener en cuenta las características personales (y del 14 % si se tienen en cuenta). Las mujeres directivas solamente representan el 16 %. Si nos fijamos en los consejos de administración de las empresas cotizadas, apenas llegan al 26 %, cifra que se reduce al 5,5 % cuando nos fijamos en las consejeras ejecutivas. También, encontramos que las mujeres están infrarrepresentadas en las carreras STEM (ciencia, tecnología, ingeniería y matemáticas). A pesar de que más mujeres que hombres acceden a la universidad, únicamente el 11 % de las mujeres obtuvieron un título en STEM, mientras que en el caso de los hombres, ese porcentaje se eleva al 36 %.

Para cerrar la brecha, primero tenemos que entender cuáles son las barreras que impiden a las mujeres alcanzar altos cargos. Existe una amplia bibliografía que provee argumentos del lado de la oferta como: a las mujeres no les gusta la competencia por los ascensos (Niederle y Vesterlund, 2010); las mujeres evitan el estrés y el desequilibrio entre la vida laboral y personal de los altos cargos (Azmat y Ferrer, 2017); interrupciones de la carrera profesional debido al cuidado de los hijos (Bertrand, Goldin y Katz, 2010)¹. Sin embargo, los mecanismos del lado de la demanda del llamado techo de cristal son mucho menos conocidos, aunque se ha mostrado que puede existir sesgos por estereotipos (Reuben, Sapienza y Zingales, 2014; Bordalo, Coffman y Gennaioli, 2019, y Bohren y Rosenberg, 2019).

En un reciente artículo Conde-Ruiz *et al.* (2022) intentan contribuir a esta literatura, mostrando que el fenómeno del techo de cristal puede ser debido a diferencias “horizontales” entre hombres y mujeres. Por diferencias horizontales nos referimos a diferencias entre hombres y mujeres que no afectan a su productividad, por ejemplo, su cultura, sus aficiones o el área en que están especializados o están trabajando. Conde-Ruiz *et al.* (2022) proponen un modelo teórico que explica cómo las diferencias horizontales pueden generar brechas de género. El modelo tiene las siguientes características. Hombres y mujeres pertenecen a dos grupos que son iguales en términos de productividad esperada (aunque dentro de los grupos los individuos son heterogéneos en términos de talento, pero exante idénticos) pero que se diferencian horizontalmente. La productividad de los trabajadores se observa imperfectamente y la evalúa un comité de evaluación mediante entrevistas e indicadores similares. El resultado de este proceso de evaluación determina las retribuciones de los trabajadores (oportunidades de carrera) y sus promociones. Los miembros del comité tienen un sesgo en la precisión de la evaluación, aunque son imparciales y su objetivo es promocionar a los trabajadores con la mayor productividad. No obstante, son mejores evaluando a trabajadores del mismo grupo (por ejemplo, porque la comunicación es mejor). Hombres y mujeres tienen el mismo peso en el conjunto de la población, pero las mujeres pueden estar infrarrepresentadas en los comités de promoción (por ejemplo, tal como hemos comentado anteriormente, la proporción de directivas es menor que la de los hombres). Si esto sucede inicialmente, aunque no son discriminadas explícitamente, son evaluadas peor.

Si suponemos que la productividad de los trabajadores depende de la inversión en capital humano específico², y los incentivos a invertir en capital humano dependen de la calidad de la evaluación por parte de estos comités, podemos concluir que la infrarrepresentación en los comités conlleva que las mujeres tienen menos incentivos a invertir en capital humano y Conde-Ruiz *et al.* (2022) muestran que esto puede llevar a una “trampa” dinámica. Consideremos que la composición de los comités se determina endógenamente según la proporción de cada grupo entre los trabajadores identificados como más productivos en el periodo

¹ Véase Matsa y Miller (2011) para una breve revisión de esta literatura.

² El capital humano va más allá del nivel de educación observable, lo debemos considerar como un concepto amplio que recoge todos los atributos y las inversiones en el aumento de la productividad en dimensiones difíciles de evaluar. Siguiendo a Arrow (1973), podemos incluir entre ellos la constancia, la puntualidad, la capacidad de respuesta, el liderazgo, el esfuerzo en la experiencia laboral previa o la iniciativa.

anterior. En ese caso, si inicialmente las mujeres están infrarrepresentadas en los comités, las mujeres invertirán menos en capital humano, promocionarán en menor proporción que los hombres y como consecuencia seguirán estando infrarrepresentados en los comités, generando un estado estacionario en el que existe una brecha de género.

En definitiva, Conde-Ruiz *et al.* (2022) demuestran que diferencias horizontales entre géneros pueden generar una brecha de género permanente. Siniscalchi y Veronesi (2020) obtienen un resultado similar centrándose en el mercado laboral académico y señalan una trampa de discriminación involuntaria vinculada al que llaman sesgo de autoimagen. Estos autores construyen un modelo de generaciones solapadas con dos grupos de investigadores con características de investigación igualmente deseables (pero ligeramente diferentes) y distribuciones de productividad *ex ante* idénticas. En el modelo, los investigadores veteranos (que estén en su segundo periodo) evalúan a los investigadores jóvenes y tienen un sesgo hacia aquellos que investigan en un campo similar al suyo. Como en Conde-Ruiz *et al.* (2022), en este entorno si un grupo está ligeramente sobrerrepresentado entre los evaluadores, este grupo (y sus características específicas de investigación) pueden dominar para siempre.

Por lo tanto, Conde-Ruiz *et al.* (2022) y Siniscalchi y Veronesi (2020) demuestran que diferencias horizontales de género independientes de la productividad, pueden generar brechas en las remuneraciones y promociones entre hombres y mujeres. En este trabajo, vamos a identificar diferencias horizontales entre hombres y mujeres en el entorno académico de la economía (y luego específicamente en las finanzas) que pueden potencialmente ayudar a explicar la clara evidencia de brecha de género en este sector. En las universidades americanas en el campo de la economía, a principios de este siglo, el 35 % de los estudiantes de doctorado y el 30 % de los profesores ayudantes eran mujeres. Desde entonces, estas cifras no han aumentado y la proporción de profesoras ayudantes en las 10 mejores escuelas ha descendido, siendo menos del 20 % en 2019. Las cifras de titulares y catedráticas no son significativamente mejores.

3. APRENDIZAJE AUTOMÁTICO, ANÁLISIS DE DATOS Y DIFERENCIAS HORIZONTALES EN LA INVESTIGACIÓN EN ECONOMÍA

Dados estos resultados es importante indagar si efectivamente existen diferencias horizontales entre hombres y mujeres en la investigación en economía que pudieran ayudar a explicar las brechas de género observadas. Para ello, vamos a analizar (siguiendo a Conde-Ruiz *et al.*, 2022) todos los artículos publicados en las principales revistas de investigación económica durante el periodo 2002-2019. Estas revistas denominadas *Top Five* (T5) son: *The American Economic Review*, *Econometrica*, *The Journal of Political Economy*, *The Quarterly Journal of Economics*, y *The Review of Economic Studies*. En total se trata de 5.311 artículos, que utilizamos para crear una base de datos donde para cada artículo recogemos los nombres de los autores, la fecha de publicación, la revista y el resumen del mismo. La idea central es utilizar esta base de datos para caracterizar los patrones de publicación de hombres y mujeres

en estas revistas líderes. La idea de centrarnos en publicaciones en las T5 para este objetivo se puede justificar por diferentes razones. Primero, el proceso de publicación se parece mucho a los procesos de evaluación por comités de los artículos teóricos que fundamentan la investigación. En segundo lugar, la influencia de las publicaciones T5 es enorme, tanto en lo referente a la investigación en sí misma (dado que estas publicaciones son a su vez las más citadas) como en las carreras profesionales y la promoción de los investigadores. Heckman y Sidharth (2020) analizan las decisiones de *tenure* (la promoción a un contrato permanente de un investigador) de los 35 departamentos de economía más importantes de EE. UU. y concluyen que las publicaciones en T5 son una variable explicativa muy potente de la promoción a *tenure*.

La estrategia que vamos a seguir en nuestro análisis empírico es identificar los temas de investigación que hay detrás de las publicaciones seleccionados y verificar si la distribución de estos temas, difiere entre hombres y mujeres. Una primera forma de llevar a cabo este análisis sería centrarnos en los denominados códigos JEL de los propios artículos. Sin embargo, estos códigos tienen muchas limitaciones, primero son demasiado amplios y frecuentemente no son una buena descripción de los temas tratados en el artículo. Luego son asignaciones arbitrarias realizadas por los mismos autores. En su lugar, nuestra estrategia empírica consiste en utilizar técnicas de aprendizaje automático no supervisado para descubrir la estructura oculta de nuestros documentos de texto³. El aprendizaje automático además de modelos predictivos, se utiliza para identificar patrones en grandes bases de datos, reduciendo su dimensionalidad en un número limitado de variables. Con otras palabras, queremos proporcionar una representación de baja dimensión (temas) de un objeto de alta dimensión (resúmenes), conservando en lo posible su contenido informativo. En nuestro problema esto significa que tomando como variable de entrada los propios resúmenes de los artículos, identifique los temas de investigación y asigne los artículos a ellos. Por no supervisado denotamos la ausencia de intervención humana para identificar dichos temas latentes.

Del universo de algoritmos de análisis de textos que existen para la estimación de temas, hemos elegido el *Structural Topic Model (STM)* desarrollado por Roberts, Stewart y Tingley (2019). La ventaja de este algoritmo es que permite incorporar metadatos a nivel de documento en un modelo de texto probabilístico. En nuestro caso, para mejorar la estimación de los temas, se puede utilizar la información adicional de los artículos, referente a los nombres de las revistas y las fechas de publicación. Aunque vamos a utilizar el algoritmo *STM*, este puede interpretarse como un refinamiento del algoritmo *LDA (Latent Dirichlet Allocation)* desarrollado por Blei (2003), que es el algoritmo de aprendizaje automático más popular en la reducción de la dimensionalidad de los documentos de texto⁴. A continuación, queremos explicar la idea central del funcionamiento del algoritmo y cómo se estiman los temas.

Comenzamos describiendo el tratamiento de los datos. Extraemos todas las palabras de nuestros 5.311 resúmenes (o documentos). En primer lugar, tenemos que “limpiar” este

³ Para una excelente introducción no técnica al aprendizaje automático, véase Hansen, McMahon y Prat (2017).

⁴ Para la descripción técnica del algoritmo *LDA*, véase el artículo original de Blei (2003) y también Hansen, McMahon y Prat (2017) que es el primer documento que utiliza el algoritmo *LDA* en la literatura económica.

conjunto de palabras para reducir el vocabulario y seleccionar los términos con más contenido informativo. Centrarnos en las palabras con más significado semántico, nos ayuda a estimar mejor los temas. El *corpus* es el conjunto de palabras únicas que obtenemos, después de convertirlas a minúsculas y eliminar del texto original en bruto las palabras sin significado semántico utilizando la lista SMART, desarrollada en la Universidad de Cornell en 1960. Eliminamos, por ejemplo, preposiciones como “para” o “en”. Además, reducimos las palabras hasta obtener su raíz lingüística original (“educ” en lugar de “education”) y eliminamos las palabras que aparecen solamente una o dos veces. Este proceso en nuestro caso, transformó un conjunto de 13.835 términos diferentes a un *corpus* de 4.241 palabras únicas.

El segundo paso es representar nuestros datos de texto en una matriz documentos-términos de D filas (5.311 resúmenes) y V columnas (4.182 palabras únicas en nuestro *corpus*) donde el elemento (d, v) de la matriz es el número de veces que la palabra v_{th} aparece en el resumen d_{th} . Esta matriz documentos-términos que reduce la dimensionalidad de nuestras variables de texto originales es el *input* del algoritmo. Nuestro objetivo es encontrar un modelo probabilístico que sea capaz de explicar la matriz documentos-términos en dos pasos adicionales. Primero, identificando K temas en nuestros *corpus* y luego representando los documentos como una combinación de esos temas. ¿Qué es un tema? El tema k es una distribución de probabilidad β_k sobre todas las palabras únicas de nuestro *corpus*, donde β_k^v es la probabilidad de que el tema k genere la palabra v . Cada documento d tiene su propia distribución sobre el conjunto de temas θ_d . Esto significa que cada documento/resumen es una combinación lineal de los temas. Por tanto, θ_d^k significaría el peso del tema k en el documento d . El modelo probabilístico de temas se describe mediante estas distribuciones de temas β_k y de documentos θ_d . Teniendo en cuenta esto, la probabilidad de que una palabra elegida arbitrariamente en el documento d coincida con el término v_{th} es $p_{dv} = \sum_k \beta_k^v \theta_d^k$. Utilizando estas probabilidades, podemos obtener la probabilidad total de nuestros datos, $\prod_d \prod_v p_{d,v}^{n_{d,v}}$, donde $n_{d,v}$ corresponde a los elementos de la matriz documentos-términos (el número de veces que la palabra v_{th} aparece en el documento/resumen d_{th})⁵.

Una variable importante del algoritmo es el número de temas a estimar. Podemos seguir dos estrategias. Una, encontrar el número de temas que mejor se ajuste a los datos, lo que suele conducir a un K óptimo que normalmente es un número grande. En nuestro caso este número es $k = 54$. El problema de esta estrategia es que los temas no son fácilmente interpretables. La alternativa es forzar al algoritmo a utilizar un número determinado de temas para facilitar el contenido semántico de los mismos. En la última parte de este artículo forzaremos el algoritmo a estimar 15 temas y con ello será más sencilla la identificación de estos temas⁶.

⁵ Véase Hansen, McMahon y Prat (2017) para una descripción precisa del cálculo de la probabilidad total.

⁶ En Conde-Ruiz *et al.* (2022) ampliamos la muestra original para incluir los resúmenes de 1.117 artículos publicados como *Papers* y *Proceeding* en AER, entre 2011 y 2018 (antes de 2011 este tipo de trabajos no tienen resúmenes y después de 2018 se publican en otra revista). Con esta nueva muestra ampliada el número óptimo de temas aumenta hasta $K = 70$. Aunque estos nuevos artículos incorporados son muy cortos y con procesos editoriales muy diferentes a los de los envíos regulares, esta muestra ampliada genera interesantes resultados adicionales a los presentados en este capítulo.

Una vez estimados los temas y asignados los resúmenes a ellos, para analizar cómo esta distribución depende del género, debemos determinar el género de los autores, dado que no observamos directamente el género en nuestros datos. Para resolver este problema, clasificamos a los autores por género según su nombre de pila. Nos basamos en tres bases de datos diferentes: la base de datos de nombres de pila publicada por la Administración de la Seguridad Social de EE.UU., creada a partir de los datos de las solicitudes de tarjetas de la Seguridad Social; la base de datos construida por Tang *et al.* (2011), que utiliza Facebook para recopilar datos sobre los nombres de pila y el género autodeclarado; y, por último, la base de datos de nombres desarrollada por Bagues (2017). Comprobamos manualmente cualquier candidato que (a) esté dentro del intervalo de probabilidad [0,05 0,95] de ser hombre/mujer o (b) no se encuentre en ninguna de las bases de datos. Una vez hecho esto, convertimos la muestra original de artículos en una muestra de artículos-autores. Transformamos los 5.311 artículos originales en una muestra total de 11.721 (con 9.840 artículos-autores masculinos y 1.881 artículos-autoras). Salvo que se indique lo contrario, todas las medidas que figuran a continuación se calculan sobre esta muestra aumentada de artículos-autores.

4. DIFERENCIAS DE GÉNERO EN LOS TEMAS DE INVESTIGACIÓN EN ECONOMÍA

Siguiendo Conde-Ruiz *et al.* (2022) empezamos presentando los 54 temas estimados por el algoritmo STM en la [figura 1](#) que muestra cada tema asociándolo a sus palabras clave. A pesar de que los temas estimados recogen además del objeto de la investigación, potencialmente la metodología o el estilo, podemos identificar algunos temas por la prevalencia de sus palabras clave. Por ejemplo, el tema 28 parece estar relacionado con el Comercio Internacional, mientras que el tema 9 puede asociarse a la Teoría Econométrica.

4.1. Prevalencia de los temas

Una vez estimados los temas de investigación, el siguiente paso es asignar a los mismos los documentos. En particular, asociamos un resumen d a diferentes temas de acuerdo con la distribución subyacente θ_d . La [figura 2](#) muestra los temas latentes estimados, donde el tamaño del círculo es proporcional al número esperado de documentos en el tema (también hemos reproducido numéricamente esta información en una columna de la [figura 1](#)).

La [figura 2](#) también contiene información sobre la conectividad entre los temas. Por ejemplo, si el tema latente k está más cerca de k' que de k'' , significa que la distribución β_k se parece más a la distribución $\beta_{k'}$ que a la distribución $\beta_{k''}$. Observando la [figura 1](#) y la descripción de los temas latentes en la [figura 2](#), surgen algunos patrones interesantes. Por ejemplo, los temas 11, 9 y 21 (“Teoría Econométrica”), que ya se han discutido anteriormente, están en cierto modo aislados del resto de temas. En la [figura 2](#) también podemos identificar algunos otros clusters de temas, por ejemplo (al este en la [figura 2](#)) 51, 34, 23, 2, etc., son temas relacionados con macrofinanzas, más cercanos a los de Teoría Econométrica, pero no tanto; (oeste en la [figura 2](#)) 50 es un nodo central de un conjunto de temas relacionados con econo-

Figura 1.

Los K temas óptimos ordenados por su prevalencia en el corpus

Topic 28	trade	countri	product	export	intern	import	firm	sector	factor	develop	3.8%	17.8%
Topic 9	estim	method	sampl	data	asymptot	paramet	consist	use	error	bias	3.5%	13.4%
Topic 11	condit	variabl	function	identif	identifi	restrict	estim	distribut	instrum	bound	3.3%	15.5%
Topic 29	experi	subject	experimen	behaviort	treatment	predict	learn	evid	theori	differ	2.8%	17.5%
Topic 22	prefer	choic	decis	util	individu	make	altern	behavior	set	maker	2.7%	14.1%
Topic 21	test	statist	asymptot	distribut	method	paramet	confid	propos	forecast	bootstrap	2.7%	15%
Topic 19	school	student	effect	educ	colleg	score	test	teacher	program	assign	2.6%	17.8%
Topic 48	wage	worker	employ	firm	product	job	increas	labor	plant	skill	2.6%	15.4%
Topic 37	equilibrium	dynam	general	equilibria	exist	economi	condit	stochast	solut	uniqu	2.5%	10.8%
Topic 51	shock	polic	monetari	inflat	aggreg	respons	money	real	nomin	volatil	2.4%	13.2%
Topic 16	belief	agent	expect	prior	ration	probabl	signal	util	set	learn	2.3%	10.1%
Topic 6	game	player	strategi	payoff	equilibrium	play	bargain	repeat	cooper	equilibria	2.3%	10.4%
Topic 2	price	cost	adjust	chang	data	firm	demand	good	markup	relat	2.3%	17%
Topic 49	women	children	parent	chang	femal	men	famili	educ	marriag	child	2.2%	32.8%
Topic 53	market	inform	trade	price	asset	valu	trader	privat	advers	select	2.2%	15.1%
Topic 15	welfar	cost	benefit	insur	gain	polic	estim	loss	reduc	use	2.2%	18.7%
Topic 33	return	firm	stock	manag	asset	equiti	investor	portfolio	predict	size	2.2%	18.4%
Topic 32	contract	agent	princip	commit	optim	hazard	incent	moral	inform	problem	2.1%	11.6%
Topic 50	polic	polit	govern	parti	elect	voter	power	politician	elector	public	2%	13.5%
Topic 34	financi	invest	constraint	recess	shock	asset	firm	aggreg	credit	financ	2%	15.6%
Topic 3	risk	avers	consumpt	ambigu	util	discount	prefer	expect	asset	intertempor	2%	14.5%
Topic 47	consum	firm	product	demand	market	good	price	profit	advertis	competit	1.9%	15.1%
Topic 41	percent	health	insur	increas	hospit	estim	care	patient	drug	use	1.9%	22%
Topic 18	region	econom	area	local	growth	land	agricultur	local	develop	data	1.9%	14.4%
Topic 43	household	hous	consumpt	spend	incom	expenditur	increas	effect	respons	data	1.8%	15.1%
Topic 45	cycl	busi	product	industri	fluctuat	chang	demand	volatil	aggreg	entri	1.8%	14.4%
Topic 40	optim	alloc	effici	distort	economi	privat	condit	ineffici	resourc	polic	1.8%	14.1%
Topic 27	incom	earn	inequ	data	differ	measur	survey	distribut	use	mobil	1.7%	17.4%
Topic 52	capit	human	invest	skill	growth	accumul	differ	labor	account	life	1.7%	14.5%
Topic 26	market	match	stabl	friction	competit	labor	agent	labour	side	type	1.7%	15.6%
Topic 25	technolog	innov	product	new	firm	patent	research	adopt	knowledg	spillov	1.7%	19.5%
Topic 44	inform	coordin	action	communic	strateg	payoff	game	outcom	sender	signal	1.6%	14.9%
Topic 10	mechan	implement	incent	transfer	type	design	compat	post	agent	problem	1.6%	10.9%
Topic 5	auction	bid	bidder	buyer	seller	valu	price	revenu	privat	inform	1.6%	14.8%
Topic 4	state	unit	right	issu	econom	protect	problem	institut	properti	resourc	1.5%	15.3%
Topic 12	social	network	individu	incent	interact	opportun	depend	connect	link	secur	1.5%	19.9%
Topic 17	bank	credit	polic	fund	crisi	lend	liquid	loan	financi	market	1.5%	14.5%
Topic 42	public	regul	enforc	good	privat	law	provis	punish	legal	cost	1.5%	18%
Topic 13	work	program	labor	suppli	hour	increas	transfer	time	particip	home	1.4%	18%
Topic 20	tax	reform	incom	rate	increas	taxat	margin	chang	optim	effect	1.4%	16.9%
Topic 23	debt	default	borrow	govern	credit	bond	fiscal	sovereign	market	matur	1.4%	16.8%
Topic 1	econom	studi	name	correct	bias	black	measur	data	signific	racial	1.3%	18.7%
Topic 30	firm	contract	ownership	vertic	integr	adopt	industri	cost	supplier	exclus	1.3%	21.8%
Topic 38	group	ethnic	member	trust	evid	segreg	countri	increas	cultur	chang	1.3%	19.8%
Topic 36	inform	vote	signal	voter	aggreg	bias	privat	strateg	elect	larg	1.3%	15%
Topic 39	rate	exchang	interest	currenc	countri	real	patient	donor	regim	transplant	1.2%	13.6%
Topic 31	save	citi	retir	account	popul	life	increas	german	individu	rate	1.2%	19.4%
Topic 7	vote	news	voter	media	candid	elect	estim	committ	newspap	bias	1.2%	17.5%
Topic 8	search	unemploy	worker	job	distribut	durat	wage	rate	employ	benefit	1.2%	14.7%
Topic 35	conflict	increas	violenc	crime	war	polic	outsid	option	effect	attack	1.1%	17.1%
Topic 14	rule	demand	set	ration	problem	yield	constitut	optim	function	util	1%	10.5%
Topic 46	project	effort	team	perform	redistribut	outcom	win	competit	one	prize	0.9%	19.4%
Topic 24	qualiti	delay	probabl	accept	fee	order	card	offer	paper	higher	0.8%	14.8%
Topic 54	import	use	addit	data	sever	relat	support	analys	find	limit	0.3%	15.7%

Topic Female Prop. Prop.

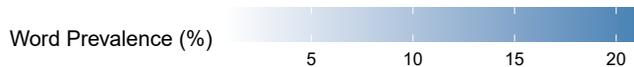
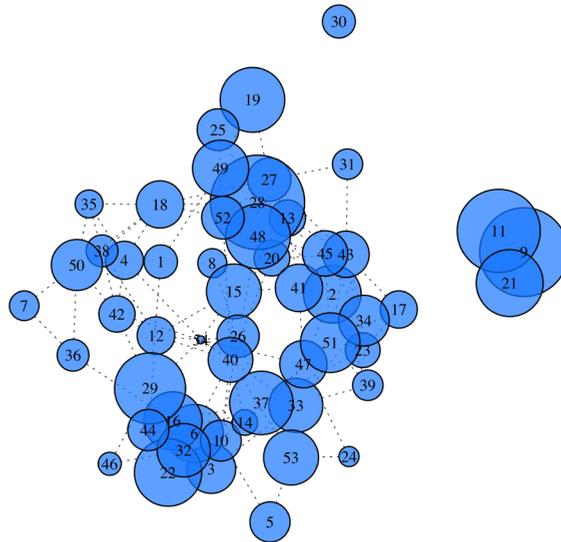


Figura 2.

Conectividad entre los temas y la proporción de documentos en cada tema (la distribución θ_d)



mía política e instituciones), (suroeste en la [figura 2](#)) 29, 32, 22, etc., son temas relacionados con la microeconomía (teoría de contratos, teorema de la decisión, etc.). Por último, las áreas aplicadas como la economía del trabajo, el desarrollo internacional o la economía política se sitúan en torno a los temas 19, 49, 28 y 48 (norte en la [figura 2](#)). En Conde-Ruiz *et al.* (2022), realizamos un análisis más formal de la distancia entre temas utilizando un análisis de correspondencia simple.

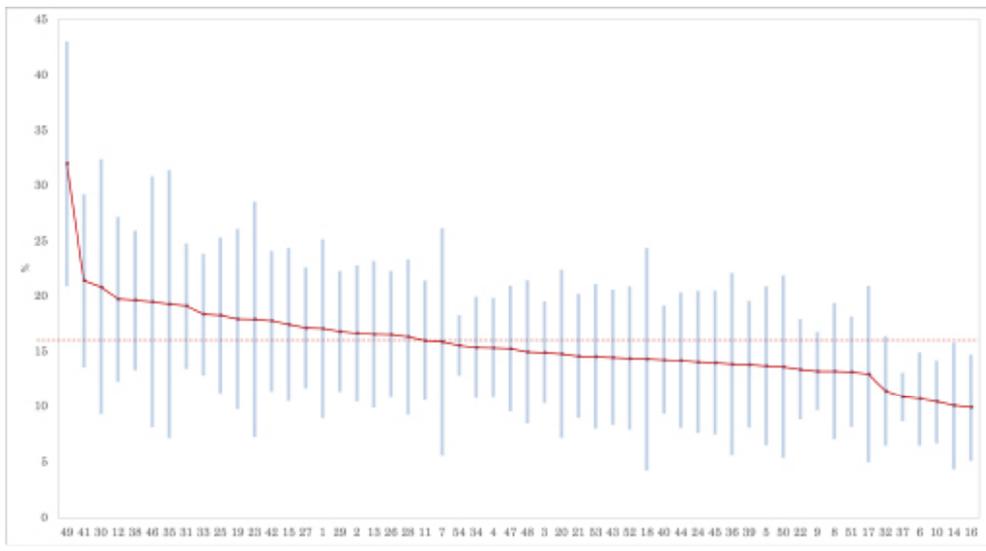
La [figura 3](#) repite el análisis pero el tamaño del círculo representa esta vez la proporción de autoras mujeres en el tema. Los tamaños relativos de los temas han cambiado dado que encontramos que la distribución por género es diferente entre las diferentes áreas. La [figura 3](#) es la primera evidencia de que existen diferencias horizontales entre hombres y mujeres en las publicaciones, y por lo tanto en los temas de investigación. Esto se ilustra bien, con un pequeño subconjunto de temas (norte en la [figura 3](#)) aparentemente relacionados con Economía Aplicada, especialmente el tema 49, con una proporción relativamente alta de mujeres, y por el contrario otro conjunto de temas (por ejemplo, el sudoeste en la [figura 3](#)) que están estrechamente conectados y en los que la presencia de mujeres es escasa (en esos temas aparecen términos frecuentemente utilizados en la Teoría Económica).

Para ilustrar esta intuición vamos a analizar con mayor detalle, los temas donde la proporción de autoras es mayor, el tema 49 (32,8 %), y el tema 16 donde el porcentaje de autoras sólo llega al 10,1 %. Para ello, la [figura 4](#) representa estos dos temas como nubes de palabras, donde el tamaño de los términos en la nube es equivalente a su probabilidad en la distribu-

Conde-Ruiz *et al.* (2022) ilustra las diferencias horizontales en temas de investigación con dos figuras muy informativas. La **figura 5** muestra la media de la presencia de autoras por tema ordenadas de mayor a menor (la media es del 15,9 % en el periodo 2002-2019), junto con la desviación estándar de esta presencia a lo largo de la muestra de años. Esta **figura** muestra claramente la prevalencia relativa de las mujeres con respecto a los hombres en algunos temas, mientras que en otros, la representación es muy pequeña.

Figura 5.

Sobre la prevalencia de autores mujeres por tema: media y una desviación estándar a lo largo del tiempo

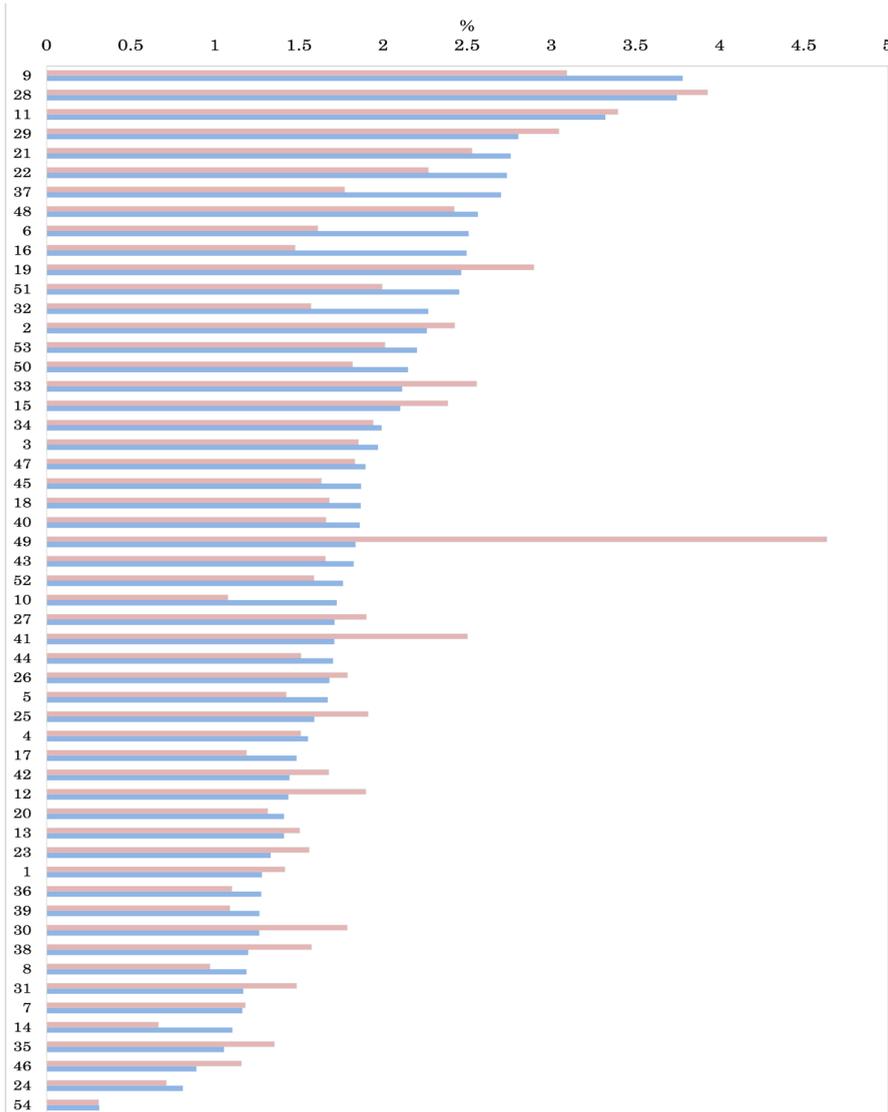


No obstante, para tener una imagen más precisa de estas diferencias “horizontales”, debemos añadir la información relativa a la prevalencia de los temas. Es posible que las mujeres no estén representadas en un tema concreto y que esta circunstancia tenga poco impacto en la medida en que este tema contenga muy pocos trabajos publicados. La **figura 6** muestra la distribución entre hombres y mujeres en los temas normalizados por tener el mismo tamaño. Esto nos da la probabilidad de que, por ejemplo, un artículo de autoría femenina pertenezca a cualquiera de los 54 temas. Clasificamos los temas según la probabilidad de que los elija un autor masculino. Esta **figura** demuestra que los autores masculinos y femeninos tienen preferencias diferentes o siguen estrategias distintas a la hora de realizar y publicar sus investigaciones. Observamos que los temas con mayor “demanda” por parte de los hombres también son muy solicitados por las mujeres. Sin embargo, hay un conjunto de temas, para los que la proporción de artículos publicados por los hombres es alta, que son menos atractivos (o más difíciles de publicar) para las mujeres. En general, las distribuciones masculina y femenina son diferentes, con la característica sobresaliente del tema 49 para las mujeres, que es un claro pico en la distribución femenina de los trabajos publicados.

El análisis de los textos sobre todas las publicaciones en T5 realizadas entre 2002 y 2019 provee una evidencia clara de que entre los hombres y las mujeres existen diferencias horizontales respecto a la elección de temas de investigación.

Figura 6.

Distribuciones empíricas por temas entre hombres y mujeres (con la condición de haber publicado un artículo en el *Top 5*)

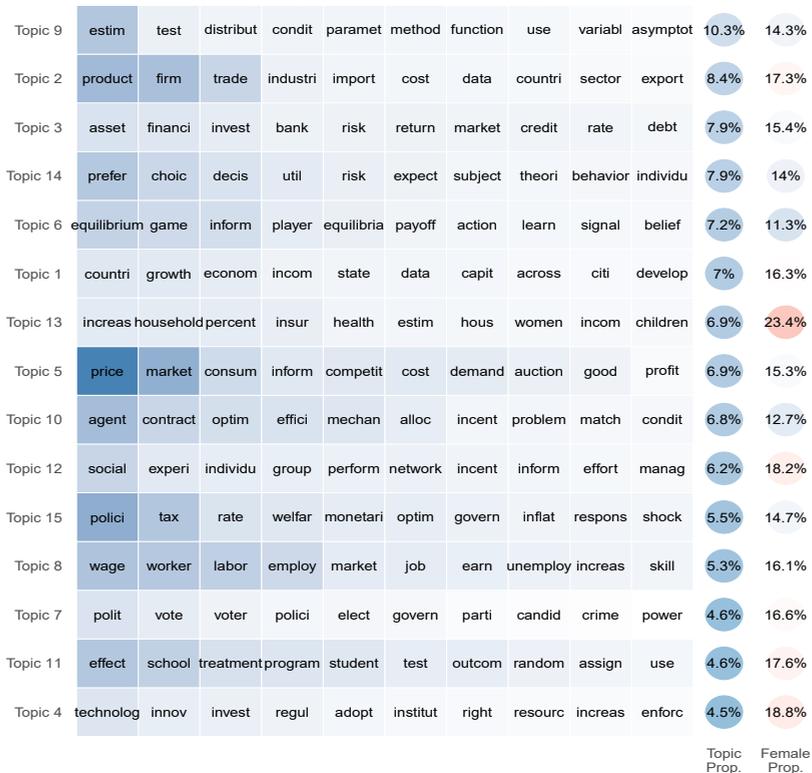


5. TEMAS ESTIMADOS COMO ÁREAS DE INVESTIGACIÓN: FINANZAS, MAYORITARIAMENTE COSA DE HOMBRES

En esta sección vamos a reducir el número de temas hasta el punto de que podemos identificar cada tema con un campo de investigación. Hemos visto como cuando el número de temas es alto, no sólo identificamos el área de investigación sino también aspectos semánticos, o forma de enfocar la investigación. Al reducir K o el número de temas, por un lado, facilita la interpretación semántica de los temas y luego permite analizar, por ejemplo, si el peso de un campo concreto en el *Top 5* ha aumentado con el tiempo. Por último, un número bajo de temas nos permitirá enmarcar nuestros resultados con la literatura anterior que ha utilizado un número reducido de categorías vinculadas a los códigos JEL y las áreas de investigación de los principales departamentos.

Figura 7.

Temas latentes ordenados por prevalencia en el *corpus* con $K = 15$



Analizando de forma manual distintos números de temas, encontramos que para $k = 15$ el modelo estimado funciona mejor en términos de ajuste con los datos, y en términos de coincidencia del *topic* latente y el campo de investigación. El modelo con $k = 15$ temas latentes se resume en la **figura 7**, donde se puede ver que el tema 3, coincide plenamente con Finanzas. Vemos como en el área de Finanzas se han publicado el 7,8 % de todos los artículos aparecidos en las revistas *Top 5* y como tan sólo el 15,4 % de los autores que han publicado en esta área son mujeres.

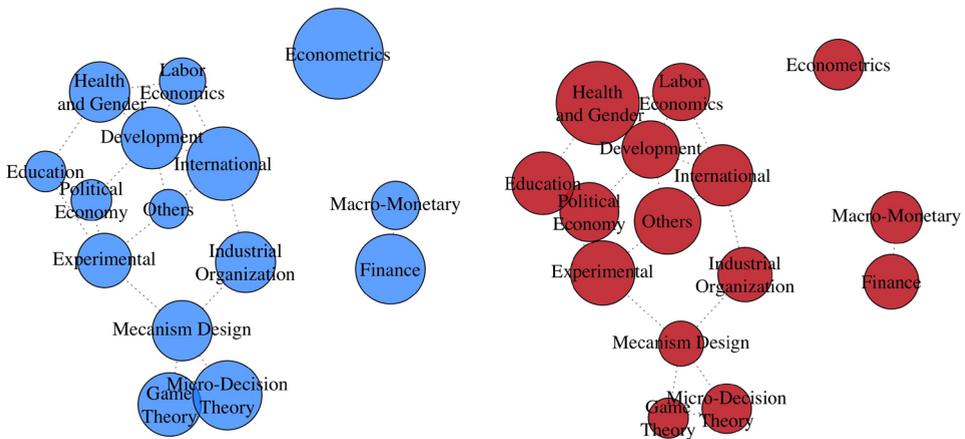
Cuando hacemos un análisis de las distancias entre temas o áreas de investigación vemos como “Finanzas” está bastante aislado del resto de temas y tan sólo tiene conexión con “Macroeconomía Financiera”, mientras que hay otros campos que están mucho más conectados. En la **figura 8** vemos también como esta geografía o distancias entre áreas de investigación es similar entre hombres y mujeres, aunque en la distribución entre áreas por género (*i.e.* el tamaño de los círculos), las mujeres trabajan en términos proporcionales menos que los hombres en el área de “Finanzas”. También, vemos cómo los artículos publicados por mujeres están sobrerrepresentados en el área de “Economía de la Salud y Género”.

Figura 8.

Conectividad entre los temas para $K = 15$

(a) Conexión entre temas y fracción de documentos/resúmenes en cada *topic* (o área de investigación) (θ_d distribution)

(b) Conexión entre los temas y los documentos/resúmenes de autoras en cada *topic* (o área de investigación)

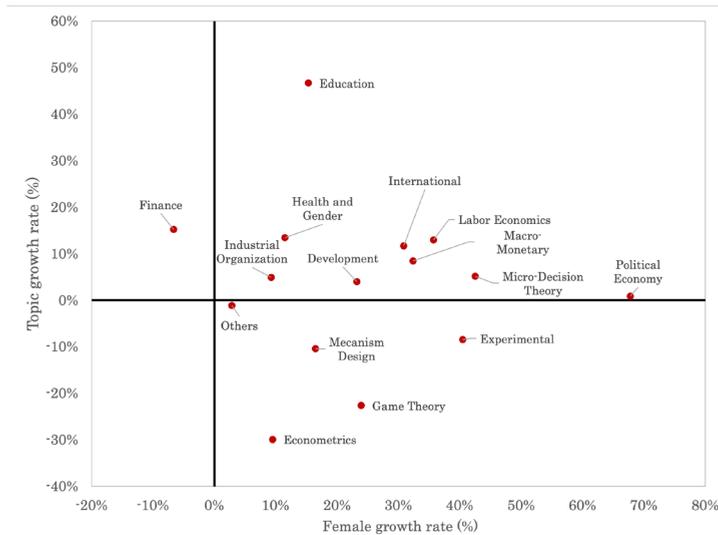


La **figura 9** analiza conjuntamente la evolución de la prevalencia de los temas (o campos de investigación) y la proporción de mujeres autoras. Para construir la **figura**, hemos calculado la tasa de crecimiento de la prevalencia de los temas y la proporción de autoras utilizando los últimos siete años (2013-2019) y los primeros siete años (2002-2008). En primer lugar, podemos observar que la proporción de mujeres ha aumentado en todos los temas excepto en Finanzas que ha caído un 6,6 %. Este dato es sorprendente, pues a pesar del aumento de

las mujeres académicas y que las publicaciones en el área de Finanzas en revistas *Top 5* han aumentado un 18 %, la presencia de mujeres autoras en ese campo sea el único en el cual han disminuido.

Figura 9.

Tasas de crecimiento de la prevalencia del área de investigación y de la proporción de mujeres en cada área



En cuanto a la prevalencia, sólo cuatro áreas de investigación han disminuido su peso en términos artículos publicados en las revistas *Top 5*: i) diseño de mecanismos (-10,3 %); ii) econometría (-29 %); iii) teoría de juegos (-22,5 %), y iv) economía experimental (-8,4 %). Salvo en finanzas, en todas las demás áreas de investigación el porcentaje de mujeres autoras han subido. Las mayores subidas se han producido en economía política (+67,7 %), teoría de la decisión (+42,5 %), macroeconomía y monetaria (+32,3 %), economía experimental (+40 %) o economía laboral (+35 %). En todos ellos las mujeres estaban claramente infrarrepresentadas.

Por otro lado, los temas en los que menos ha crecido el porcentaje de mujeres, además de finanzas, que ha disminuido, han sido en economía de la salud y género que ha aumentado un +11,4 %, en econometría con un aumento del +9,4 %, y en organización industrial (IO) que ha subido un +9,2.

Por último, no parece existir una relación clara entre la tasa de crecimiento de la prevalencia de temas y el aumento de la representación femenina. Esto creemos que es sorprendente. Sería esperable que aquellas áreas cuyas publicaciones ganan peso en las mejores revistas del

mundo, sean también en las que la presencia de mujeres autoras aumente. No disponemos de datos sobre la edad de los autores, pero como la proporción de mujeres va en aumento, cabe esperar que la proporción de mujeres entre los nuevos autores que han publicado en revistas *Top 5* sea relativamente grande. Por lo tanto, es más probable que los recién llegados trabajen en temas “candentes” que en temas en declive. La combinación de ambos efectos debería conducir a una correlación positiva entre el aumento de la prevalencia de un tema y el aumento de la representación femenina, algo que no observamos claramente en los datos.

6. CONCLUSIONES

En resumen, utilizando técnicas de aprendizaje automático no supervisado sin ninguna intervención en la determinación de los temas de investigación y la asignación de los artículos a los temas, se ha mostrado evidencia empírica de que existen diferencias horizontales entre hombres y mujeres en la elección de temas de investigación. Se ha llevado a cabo un análisis de textos utilizando para ello, todos los artículos publicados en revistas T5 entre los años 2002 y 2019. Se trata de una muestra muy relevante, dado el impacto de las revistas T5 en las carreras profesionales de los investigadores en las mejores universidades del mundo. Este resultado es importante porque los recientes resultados teóricos de Conde-Ruiz y Ganuza (2017); Conde-Ruiz *et al.* (202) y Siniscalchi y Veronesi (2020) muestran que las diferencias “horizontales” de género en la elección del tema de investigación pueden conducir a una discriminación permanente por género en la carreras profesionales académicas de economía y finanzas. Brecha de género que los datos muestran que existe y que al revés que en otros sectores, no ha mejorado significativamente en la última década.

La evidencia empírica de este capítulo esta extraída de Conde-Ruiz *et al.* (2022), artículo que profundiza además en otras dimensiones relacionadas con las diferencias de género en la investigación en economía. Por ejemplo, al escribir un artículo, un autor puede contribuir a un solo tema latente o a varios, los autores que han publicado varios trabajos pueden haber escrito artículos similares o pueden haber sido más diversos: ¿son estos patrones de diversificación diferentes para los hombres y las mujeres? Conde-Ruiz *et al.* (2022) analiza esta cuestión utilizando el índice Herfindahl-Hirschman (HHI) que se utiliza para medir la concentración en un mercado, como una medida de dispersión entre los temas. El principal resultado es que las mujeres son más diversas (HHI más bajo) cuando publican uno o dos artículos, pero menos (HHI más alto) cuando publican un mayor número de artículos en el *Top 5*. Otra perspectiva es la de Hengel (2020) que utiliza algoritmos de legibilidad para medir la calidad de la escritura de los resúmenes de los artículos⁷. Conde-Ruiz *et al.* (2022) aplican estos algoritmos de calidad de la escritura a su base de artículos T5 y concluyen que los temas más femeninos están mejor escritos que las de los temas más masculinos. Sin embargo, es difícil desentrañar el papel de la prevalencia de autoras frente a la redacción dentro de un tema.

⁷ Como Hengel (2020) discute en detalle, la legibilidad de los resúmenes está fuertemente correlacionada positivamente con la legibilidad de otras secciones de un artículo.

Referencias

- ARROW, K. J. (1973). The Theory of Discrimination. En O. ASHENFELTER y A. REES (eds), *Discrimination in Labor Markets*. Princeton University Press.
- AZMAT, G. y FERRER, R. (2017). Gender Gaps in Performance: Evidence from Young Lawyers. *Journal of Political Economy*, 125(5), pp. 221–242.
- BERTRAND, M., GOLDIN, C. y KATZ, L. (2010). Dynamics of the Gender Gap for Young Professionals in the Financial and Corporate Sectors. *American Economic Journal: Applied Economics*, 2, pp. 228–255.
- BOHREN, J. A., IMAS, A. y ROSENBERG, M. (2019). The Dynamics of Discrimination, Theory and Evidence. *American Economic Review*, 109, pp. 3395–3436.
- BORDALO, P., COFFMAN, K. y GENNAIOLI, N. (2019). Beliefs about Gender. *American Economic Review*, 109, pp. 739–773.
- CONDE-RUIZ, J. I., GANUZA, J. J., GARCÍA, M. y PUCH, L. A. (2022). Gender Distribution across Topics in Top 5 Economics Journals: A Machine Learning Approach, *SERIEs: Journal of the Spanish Economic Association*, 13, pp. 269–308.
- CONDE-RUIZ, J. I., GANUZA, P. y PROFETA, J.-J. (2017). Statistical Discrimination and the Efficiency of Quotas. *Fedea Working Papers*.
- CONDE-RUIZ, J. I., GANUZA, P. y PROFETA, J.-J. (2022). Statistical discrimination and committees. *European Economic Review*, 141, 103994.
- HANSEN, S., MCMAHON, M. y PRAT, A. (2017). Transparency and Deliberation Within the FOMC: A Computational Linguistics Approach. *The Quarterly Journal of Economics*, 133(2), pp. 801–870.
- HECKMAN, J. y SIDHARTH, M. (2020). Publishing and Promotion in Economics: The Tyranny of the Top Five. *Journal of Economic Literature*, 58(2), pp. 419–470.
- HENGEL, E. (2020). Publishing while Female. Are women held to higher standards? Evidence from peer review. *Cambridge Working Papers in Economics*, 1753, Faculty of Economics, University of Cambridge.
- MATSA, D. A. y MILLER, A. (2011). Chipping Away at the Glass Ceiling: Gender Spillovers in Corporate Leadership. *American Economic Review*, 101(3), pp. 635–639.
- NIEDERLE, M. y VESTERLUND, L. (2010). Explaining the Gender Gap in Math Test Scores: The Role of Competition. *Journal of Economic Perspectives*, 24(2), pp. 129–144.
- REUBEN, E., SAPIENZA, P. y ZINGALES, L. (2014). How Stereotypes Impair Women's Careers in Science. *Proceedings of the National Academy of Sciences*, 111, pp. 4403–4408.
- ROBERTS, M. E., STEWART, B. M. y TINGLEY, D. (2019). STM: An R Package for Structural Topic Models. *Journal of Statistical Software, Articles*, 91(2), pp. 1–40.
- SINISCALCHI, M. y VERONESI, P. (2020). Self-image Bias and Lost Talent. December 2020, (28308).
- TANG, C., ROSS, K., SAXENA, N. y CHENN, R. (2011). What's in a Name: A Study of Names, Gender Inference, and Gender Behavior in Facebook. pp. 344–356.
- TANG, C., ROSS, K., SAXENA, N., CHENN, R., CAMPA, P. y BAGUES, M. (2017). Can Gender Quotas in Candidate Lists Empower Women? *Evidence from a Regression Discontinuity Design*, (12149).
- TANG, C., ROSS, K., SAXENA, N., CHENN, R., JORDAN, M., BLEI, D. y NG, A. (2003). Latent Dirichlet Allocation. *J. Mach. Learn. Res.*, March 2003, 3 (null), pp. 993–1022.

Sobre los autores



Andrés Alonso Robisco

Se incorporó al Banco de España en 2019 como economista senior en la División de Innovación Financiera, donde analiza las últimas tendencias en innovación financiera. Específicamente, estudia el impacto del aprendizaje automático en el modelado de riesgo crediticio y diferentes temas relacionados con la innovación financiera climática. Previamente ha trabajado en la Single Resolution Board (SRB), una agencia de la Comisión Europea, y anteriormente, en los equipos de tesorería y mercado de capitales del Instituto de Crédito Oficial (ICO), la agencia financiera española. Ha publicado artículos en varias revistas como *International Review of Financial Analysis* y *Financial Innovation*.



Gian Pietro Enzo Belloca

Es estudiante de doctorado en Economía y Empresa en la Universidad Autónoma de Madrid. Su área de interés es el análisis de grandes masas de datos en el campo económico y financiero mediante modelos econométricos y de aprendizaje automático. Posee una licenciatura y un máster en Ingeniería Informática de la Universidad Politécnica de Turín y un máster en Finanzas en el Grande École de Commerce de París concluido con una tesis sobre el mercado de las criptomonedas. Trabajó en el Banco Central Europeo en la Dirección de Economía General en el seguimiento y la previsión de la inflación.



Iván Blanco

Es profesor de Finanzas en CUNEF Universidad. Sus áreas de investigación en la actualidad incluyen: (i) Valoración de Activos y Finanzas Cuantitativas, (ii) Efectos reales de los Mercados Financieros sobre la Economía Real, (iii) Inteligencia Artificial y Tecnología. Ha publicado artículos en algunas de las principales revistas financieras y económicas internacionales, tales como *The Journal of Financial Economics*, *Journal of Corporate Finance*,

The Energy Journal o *Applied Sciences*. Antes de incorporarse a CUNEF, trabajó en BBVA y Banco Santander como analista cuantitativo (*quant*) y como *quant-trader* en Arfima Trading. Iván también ha sido asesor independiente de numerosas firmas nacionales e internacionales en aplicaciones de inteligencia artificial y estrategias de inversión.



José Manuel Carbó

Se incorporó al Banco de España en 2019 como economista sénior en la División de Innovación Financiera, donde analiza las últimas tendencias en innovación financiera. Específicamente, estudia el impacto del aprendizaje automático en el modelado de riesgo crediticio y diferentes temas relacionados con las criptomonedas y la estabilidad financiera. Antes de esto, fue consultor en ScanmarQED London e investigador asociado en Imperial College London. Es doctor en Economía por la Universidad Carlos III de Madrid. Sus intereses de investigación son el aprendizaje automático, la innovación financiera y la evaluación de políticas públicas. Ha publicado artículos en varias revistas como *Journal of Applied Statistics*, *Economics of Transportation*, *Financial Innovation* y *Regional Science and Urban Economics*, entre otras.



Santiago Carbó Valverde

Es licenciado en Ciencias Económicas (Universidad de Valencia). Doctor-PhD in Economics por la University of Wales (UK), catedrático de Análisis Económico de la Universitat de València, director de Estudios Financieros y director Ejecutivo del Observatorio de Digitalización Financiera de Funcas, consejero independiente de Cecabank y del Instituto Valenciano de Finanzas y consultor del Banco Mundial. Ha sido asesor de instituciones como el Banco Central Europeo y la Federal Reserve Bank of Chicago. Autor de más de 300 artículos científicos y de divulgación. Ha publicado artículos en revistas como *Review of Economics and Statistics*, *European Economic Review*, *Review of Finance*, *Journal of Money, Credit and Banking*, *Journal of Corporate Finance*, *Journal of Financial Stability*, *Journal of International Money and Finance* or *Journal of Banking and Finance*. Colaborador de medios de comunicación. Columnista de *El País*.



J. Ignacio Conde-Ruiz

Es doctor en Economía por la Universidad Carlos III de Madrid (con Premio Extraordinario), catedrático de Fundamentos del Análisis Económico en la Universidad Complutense de Madrid, y subdirector de la Fundación de Estudios de Economía Aplicada (Fedea). Es miembro del Consejo Asesor de Asuntos Económicos, órgano consultivo presidido por la vicepresidenta tercera y ministra de Asuntos Económicos y Transformación Digital (Nadia Calviño). También es consejero del Consejo Económico y Social-CES como experto en el

Grupo Tercero. A propuesta del Ministerio de Trabajo y de la Seguridad Social ha formado parte del Comité de Expertos encargado de desarrollar el Factor de Sostenibilidad de las pensiones en el año 2013. Es presidente del Foro de Expertos del Instituto Santalucia. También ha trabajado en la Oficina Económica del Presidente del Gobierno como director general de Política Económica (2008-2010) y como consultor externo del Banco Mundial.

Ha realizado trabajos de investigación y docencia en la Universitat Autònoma de Barcelona, en el European University Institute de Florencia, en la Università Bocconi en Milán y en la Universitat Pompeu Fabra. Sus áreas de investigación son la economía política, la economía pública (mercado de trabajo y sistema de pensiones) y la macroeconomía. Su investigación ha sido publicada en revistas académicas como *European Economic Review*, *The Review of Economic Studies*, *Journal of the European Economic Association*, *Journal of Public Economics*, *Economic Theory*, *The Economic Journal* y *Review of Economic Dynamics*. En 2014 escribió el libro *¿Qué será de mi pensión?* (Península (Planeta)). En la actualidad está escribiendo para la misma editorial un libro titulado *Juventud Atracada*.

Pedro J. Cuadros Solas



Es doctor en Economía por la Universidad de Granada y profesor titular en CUNEF Universidad. Es economista del Observatorio de la Digitalización Financiera de Funcas. Su investigación se centra en los campos de la banca, la digitalización financiera y la intermediación financiera. Sus trabajos de investigación han sido publicados en el *Journal of Corporate Finance*, *Journal of Financial Stability*, *Journal of International Financial Markets, Institutions & Money*, *European Journal of Finance*, *Financial Innovation*, *Research in International Business and Finance*, *International Review of Economics & Finance*, *Plos-ONE* y *Global Policy*. Ha recibido (en dos ocasiones) el premio accésit de investigación de la Fundación de Estudios Financieros (FEF) y el premio a la mejor tesis de economía por la Real Academia de Doctores de España (RADE). Es investigador principal de dos proyectos (Ministerio de Ciencia e Innovación) sobre digitalización financiera.

Juan José Ganuza



Es catedrático de Economía y Empresa de la Universitat Pompeu Fabra y director de Mercados, Regulación y Competencia de Funcas. Ha publicado en las principales revistas internacionales de su campo de investigación (*RAND Journal of Economics*, *International Journal of Industrial Organization*, *Journal of Industrial Economics*, *Journal of Economics and Management Strategy*, etc.), así como en las revistas internacionales líderes en el ámbito de la economía, (como *Econométrica*), análisis económico del derecho (como el *Journal of Legal Studies*), y la gestión empresarial (como *Management Science*). Ha sido consultor de la Administración española en temas de Regulación y Contratación Pública.



Manu García

Es PhD Candidate por la Washington University in St. Louis y Research Associate del Federal Reserva Bank of St. Louis. Ha impartido clases en la Universidad Complutense de Madrid y ha sido analista de investigación en Fedea. Además, fue editor ejecutivo del blog “Nada es Gratis”. Sus áreas de investigación son la macroeconomía, las finanzas y la econometría.



Sergio J. García

Es profesor de Finanzas en CUNEF Universidad desde 2022. Obtuvo su Doctorado en Finanzas por la Universidad Carlos III de Madrid. En el pasado mantuvo posiciones en la Universidad Pontificia Comillas (ICAI-ICADE), Universitat de les Illes Balears, y como investigador visitante en la Universidad de Pennsylvania (Wharton). Su investigación se centra en la intersección entre mercados financieros, finanzas corporativas, y valoración de activos; y ha sido publicado en algunas de las principales revistas internacionales como *Journal of Corporate Finance*.



Francisco J. Nogales

Es catedrático de Estadística e Investigación Operativa del Departamento de Estadística de la Universidad Carlos III de Madrid, desde 2021. Es licenciado en Matemáticas (1995) por la Universidad Autónoma de Madrid, y doctor en Matemáticas (2000) por la Universidad Carlos III de Madrid. Es miembro sénior del Instituto de Investigación UC3M-Santander de Big Data Financiero. Recibió el premio Joven Investigador a la Excelencia Investigadora (UC3M) en 2010, 2013 y 2017. Su investigación se centra en tres áreas: (1) Optimización de Big Data: programación no lineal, optimización grande y dispersa, estimación de matrices de covarianza y precisión de alta dimensión, redes dispersas, recuperación de matrices de bajo rango. (2) Optimización bajo incertidumbre: programación estocástica, inversión de baja volatilidad, optimización de carteras bajo riesgo de estimación, optimización del valor en riesgo, optimización robusta de carteras. (3) Herramientas avanzadas de predicción: predicción de series temporales masivas, energía y finanzas, agrupación de series temporales.



Álvaro Ortiz Vidal-Abarca

Es el responsable de análisis de Big Data en BBVA Research. Dirige la unidad que lleva a cabo el análisis de Big Data para cuestiones económicas, sociales y geopolíticas. Es profesor adjunto en IE Business School y ha sido miembro del Grupo de Expertos que ha asesorado al INE en temas relacionados con Big Data. Álvaro Ortiz es doctor en Economía por la Universidad Autónoma de Madrid y posee un Diploma de Estudios Avanzados de Economía Internacional y Política

Económica por el Instituto para la Economía Mundial de Kiel (Alemania). Diploma en Machine Learning para Economistas (Cemfi) y Certificados profesionales en R (Harvard EdX) y Python (IBM). Ha presentado sus trabajos en numerosas conferencias organizadas por NBER, CEPR y AEA-ASSA, así como en conferencias organizadas por bancos centrales (BCE, Reserva Federal, Banco de Inglaterra, Banco de Suecia, Banco de Italia, Hong Kong Monetary Authority y Banco de Turquía)... Ha sido KeyNote Speaker en conferencias organizadas por el Ministerio de Economía Alemán y en el Banco de Italia. Ha publicado en varias revistas académicas como *Royal Society Open Science*, *CEPR Discussion Papers*, *Cambridge Economics WP*, *Arxiv (Cornell)*, *Economía the Journal of Lacea*, *Bank of Spain Working Papers*, *Opec Energy Review*, *The Service Studies Journal* y *Moneda y Crédito*.

Roberto Pascual



Es Catedrático de Economía Financiera y Mercados Financieros en la Universidad de las Islas Baleares (Mallorca, España). Doctor en Economía por la Universidad Carlos III de Madrid, ha sido investigador visitante en el International Center for Finance de la Yale University (Connecticut, EE. UU.), el NYU Salomon Center de la New York University (Nueva York, EE. UU.), el European Center for Advanced Research in Economics and Statistics (ECARES) de la Université Libre de Bruxelles (Bélgica), y el Center for Financial Research de la Auckland University of Technology

(Nueva Zelanda). Su área de especialización es Microestructura de los Mercados Financieros, cuyo objeto de estudio es el diseño de los mercados financieros y su efecto sobre el resultado de la negociación (liquidez, eficiencia, volatilidad, etc.). Entre otros temas, la investigación del profesor Pascual incluye la negociación algorítmica y de alta frecuencia (HFT), los determinantes de la liquidez tanto mostrada como oculta, los mercados opacos (*dark pools*), los mecanismos de interrupción de la negociación (*circuit breakers*), la medición del riesgo de asimetrías de información, negociación continua versus subastas, y el impacto de la liquidez en la formación del precio. Su trabajo ha sido publicado en revistas como *Journal of Financial Markets*, *Journal of Banking & Finance* y *Journal of Financial Econometrics* y ha sido merecedora de diversos premios de investigación, como el *Plato Market Innovator (MI3)*, *Best Paper Award (2020)*, el *Northern Finance Association Best Paper on Market Microstructure Award (2018)*, el *Jossep de la Vega Prize de la Federation of European Securities Exchanges (FESE) (2004)*, el premio Bolsas y Mercados Españoles (BME) al mejor trabajo sobre renta variable (2019, 2017, 2012, 2007), y el premio de la Asociación Española de Finanzas (AEFIN) (2001, 2006).

Luis A. Puch



Es catedrático de Análisis Económico y director de Investigación en el Instituto Complutense de Análisis Económico, Universidad Complutense de Madrid. Doctor en Economía por la Universidad Carlos III de Madrid. Ha sido profesor para UC3M, European Economic Assoc., Univ. Valencia, UPV/EHU, IMT Lucca, EUI Florencia, UIMP y UAB; investigador en Minneapolis Fed, CEPREMAP París y Fedea; y asesor para la Sec Gral Presupuestos MEH, Abengoa, Banc Sabadell,

Metrovacesa y DCN. Ha publicado artículos en *Energy Economics*, *Journal of Economic Theory*, *Review of Economic Dynamics*, *BE Journals of Macro*, y *Annals of Economics and Statistics*, entre otras revistas de prestigio internacional. Además de su interés por los métodos computacionales en Economía, su investigación más reciente se refiere a las consecuencias agregadas de las decisiones de inversión e innovación de las empresas, y a las implicaciones de estos procesos para el crecimiento económico, el uso de energía y el medioambiente.



José Penalva

Es Profesor de Finanzas en el Departamento de Empresa de la Universidad Carlos III y miembro del Oxford-Man Institute. Es doctor en Economía por la Universidad de California, Los Ángeles (UCLA) desde 1997. Ha trabajado en la Universitat Pompeu Fabra, el IAE (CSIC), y ha sido becario de investigación del Banco de España. Ha sido investigador visitante en UCLA, Georgetown University, CalTech, Haas Business School (UC Berkeley), Oxford University, Cass Business School (London), Simon School of Business (Rochester) y en la CFTC (Commodities Futures Exchange Commission) de EE. UU. Entre sus publicaciones se encuentran revistas de prestigio internacional como *Econometrica*, *Journal of Banking and Finance*, *Review of Economic Dynamics*, *Applied Mathematical Finance*, *Journal of Risk and Insurance* y *Quarterly Journal of Finance*. Ha sido receptor de la Beca Leonardo de la Fundación BBVA 2015 y de la beca Madariaga, así como Investigador Principal (IP) en dos proyectos del Ministerio de Educación y Ciencia. Ha estado muy involucrado en la formación de futuros académicos hasta 2020 como director del máster de investigación (Master in Business and Finance) que es el principal acceso al doctorado en la Universidad Carlos III y de otras universidades (como Bocconi y el Swiss Finance Institute). Imparte docencia en el máster de investigación (parte del programa de doctorado) de la Universidad Carlos III, y ha impartido docencia en otros programas (Universitat Pompeu Fabra, Universitat Autònoma de Barcelona, University of California-Los Ángeles (como ayudante)). Ha dirigido cuatro tesis doctorales y actualmente se encuentra dirigiendo la quinta. Es coautor del manual *Algorithmic and High-Frequency Trading* publicado por Cambridge University Press con más de 4.000 copias vendidas hasta el momento y más de 350 citas en Google Scholar.



Álvaro Remesal

Es profesor del Departamento de Finanzas y Contabilidad de CUNEF Universidad desde 2018. Obtuvo un doctorado en Economía y un máster en Economía y Finanzas por el Centro de Estudios Monetarios y Financieros (CEMFI). Desarrolla sus trabajos de investigación en los campos de valoración de activos, mercados financieros y gobierno corporativo.



Tomasa Rodrigo

Es economista líder de la unidad de Big Data en BBVA Research, que se encarga de aplicar la ciencia de datos al análisis económico, social y geopolítico. Tiene una gran experiencia trabajando con infraestructuras en la nube, grandes masas de datos de índole económica, financiera y social. 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 y ejerció como docente de Econometría. También

realizó un máster de data scientist impartido por IBM, junto con numerosos cursos en ciencia de datos y machine learning. Es profesora asociada en la Universidad Carlos III y en la Universidad CEU San Pablo. Además, ha publicado en revistas académicas como *Royal Society Open Science*, *CEPR Discussion Papers*, *Cambridge Economics WP*, *Arxiv (Cornell)*, *Economía the Journal of Lacea*, *Bank of Spain Working Papers* y presentado en foros relevantes en el ámbito de la ciencia de datos como Big Data Spain, Machine Learning Spain y Google Cloud Summit.



Francisco Rodríguez Fernández

Es doctor en Ciencias Económicas y Empresariales por la Universidad de Granada. Es 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 Mundial, 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 150 artículos y publicaciones sobre el sistema financiero. Ha publicado, entre otras, en las siguientes revistas: *The Review of Economics and Statistics*, *Nature-Scientific Reports*, *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*. Columnista de *El Mundo* y *Expansión* y colaborador de otros múltiples medios de comunicación de prensa escrita y radio-televisión

Funcas
Caballero de Gracia, 28
28013 Madrid
Teléfono: 91 596 54 81
Fax: 91 596 57 96
publica@funcas.es
www.funcas.es

ISBN 978-84-17609-67-2

