

INTELIGENCIA ARTIFICIAL Y FINANZAS:
UNA ALIANZA ESTRATÉGICA

2022

BANCO DE **ESPAÑA**
Eurosistema

Documentos Ocasionales
N.º 2222

Andrés Alonso-Robisco y José Manuel Carbó

INTELIGENCIA ARTIFICIAL Y FINANZAS: UNA ALIANZA ESTRATÉGICA (*)

Andrés Alonso-Robisco

BANCO DE ESPAÑA

José Manuel Carbó

BANCO DE ESPAÑA

(*) Los autores trabajan como economistas en la División de Innovación Financiera del Banco de España, y agradecen los comentarios de Juan Ayuso, Carlos Conesa, José Manuel Marqués, Ana Fernández y Sergio Gorjón, así como las presentaciones de los ponentes y moderadores del 1.º Seminario de Inteligencia Artificial aplicada a los Servicios Financieros, organizado por el Banco de España el 17 de junio de 2022, cuyas conclusiones y reflexiones se incluyen en este documento.

La serie de Documentos Ocasionales tiene como objetivo la difusión de trabajos realizados en el Banco de España, en el ámbito de sus competencias, que se consideran de interés general.

Las opiniones y análisis que aparecen en la serie de Documentos Ocasionales son responsabilidad de los autores y, por tanto, no necesariamente coinciden con los del Banco de España o los del Eurosistema.

El Banco de España difunde sus informes más importantes y la mayoría de sus publicaciones a través de la red Internet en la dirección <http://www.bde.es>.

Se permite la reproducción para fines docentes o sin ánimo de lucro, siempre que se cite la fuente.

© BANCO DE ESPAÑA, Madrid, 2022

ISSN: 1696-2230 (edición electrónica)

Resumen

Recientes avances tecnológicos, como el almacenamiento masivo de datos y la computación en la nube, están dando lugar a un mayor uso de la inteligencia artificial en la economía y las finanzas, y modificando aspectos fundamentales tanto para entidades como para supervisores. En este documento revisamos las principales tendencias de esta transformación, especialmente el uso de algoritmos de aprendizaje automático para la predicción en entornos de incertidumbre, y detallamos algunos de los casos de uso más relevantes en la actualidad, como son la calificación crediticia, el control del fraude y la predicción macroeconómica. Para ello se utilizan en gran medida las discusiones que tuvieron lugar durante el 1.º Seminario de Inteligencia Artificial aplicada a los Servicios Financieros, organizado por el Banco de España el 17 de junio de 2022. Concluimos con una reflexión sobre la convivencia de esta tecnología con los modelos econométricos tradicionales y la necesidad de gestionar nuevos factores de riesgo asociados a su uso, como la interpretabilidad de los resultados.

Palabras clave: aprendizaje automático, inteligencia artificial, finanzas, economía.

Códigos JEL: G20, C10, C45.

Abstract

Recent technological advances, such as big data and cloud computing, are leading to greater use of artificial intelligence in economics and finance, and transforming fundamental aspects of both financial institutions and supervisors. In this paper we review the main features of this transformation, especially the use of machine learning algorithms for forecasting, and we detail some of the most relevant uses of artificial intelligence today, such as for credit scoring, fraud control and macroeconomic forecasting. To this end, we make significant use of the debates that took place during the 1st conference on Artificial Intelligence applied to Financial Services, organised by the Banco de España on 17 June 2022. We conclude with a reflection on the coexistence of this technology with traditional econometric models, and the need to manage new risk factors associated with its use, such as the interpretability of the results.

Keywords: machine learning, artificial intelligence, finance, economics.

JEL classification: G20, C10, C45.

Índice

Resumen 5

Abstract 6

1 Introducción 8

2 La transformación digital de los servicios financieros 10

3 Una alianza estratégica 12

3.1 Fortaleza: la precisión 12

3.2 Debilidad: la interpretabilidad 12

3.3 Un debate abierto 13

4 Conclusiones 15

Bibliografía 16

1 Introducción

A pesar de que los fundamentos matemáticos para el desarrollo de la inteligencia artificial (IA) han estado presentes desde los años cincuenta, su aplicación generalizada solo ha sido posible recientemente gracias a los avances tecnológicos. El aumento en la generación de datos disponibles (incluidos datos no estructurados), el abaratamiento de los costes de almacenamiento de estos (*big-data*) y la computación en la nube han permitido acceder y procesar grandes cantidades de información y a mayor velocidad, lo cual ha facilitado un impulso en el uso de IA en trabajos empíricos para la toma de decisiones¹.

Dentro de la IA, a partir de la década de los ochenta del siglo XX se populariza el aprendizaje automático o *machine learning* (ML), entendido como un subconjunto de técnicas que permiten usar modelos matemáticos para que los ordenadores aprendan automáticamente a partir de una serie de datos existentes sin instrucciones directas. Estos nuevos modelos, al igual que los de econometría tradicional, tienen por objeto principal extraer información de los datos y realizar predicciones. La diferencia entre ambos enfoques predictivos se puede enmarcar dentro del debate abierto hace más de dos décadas por el estadístico Leo Breiman² sobre las dos culturas de la modelización estadística. Por una parte, la cultura de los datos, donde podemos englobar la econometría. En ella se asume que los datos son generados por un proceso estocástico basado en un modelo teórico subyacente cuyos parámetros hay que estimar para realizar inferencia estadística. Por otra parte, la cultura algorítmica, donde englobaríamos la IA y el ML, en la cual se usan algoritmos que no se basan en un modelo teórico determinado y que tienen como objetivo realizar la mejor predicción posible, ignorando aspectos como la relación teórica subyacente que gobierna el comportamiento de los datos. Dependiendo del problema que se esté abordando, podría ser más apropiado un enfoque u otro.

Los avances mencionados al principio de este documento explican que los modelos de IA y ML cada vez tengan más presencia en las finanzas y la economía, desde un punto de vista tanto teórico³ como práctico⁴. Sin embargo, este tipo de aplicaciones han tardado más en generalizarse en este ámbito que en otras disciplinas, y aún existen reticencias para su empleo en terrenos concretos.

¿Cuáles son las razones que explican esta circunstancia? Por una parte, el poder de predicción de los modelos de ML está bien documentado. Estos modelos se ajustan bien a situaciones de elevada incertidumbre, que pueden provenir de la dificultad para derivar un modelo relacional concreto, de la existencia de patrones no lineales o de la inestabilidad temporal o espacial de la relación entre las variables subyacentes. Hoy en día encontramos

1 Véase Yeung (2020).

2 Véase Breiman (2001).

3 Véanse Varian (2014) y Athey e Imbens (2019).

4 Véase, por ejemplo, Gimeno y Marqués (2022).

aplicaciones financieras tan variadas como la evaluación de los impagos de crédito⁵ o la valoración de derivados financieros⁶. En ambos, los resultados obtenidos son satisfactorios.

Por otra parte, en economía muchas veces existe la necesidad de entender la verdadera naturaleza que rige el comportamiento de los individuos (por ejemplo, para diseñar medidas de política económica). Para ello, se precisan propiedades como la transparencia, que los modelos de ML no ofrecen naturalmente, dada su complejidad algorítmica asociada (de ahí su llamada «naturaleza de caja negra»), la cual dificulta la interpretación de sus resultados. Esta cuestión constituye también una preocupación muy relevante para los supervisores financieros⁷.

En el presente trabajo se analizan las áreas en las que el ML tiene más potencial en las finanzas y en la economía, los principales retos en su implantación y su potencial impacto en el sector financiero. Para ello, se utilizan los argumentos planteados en el 1.º Seminario de Inteligencia Artificial aplicada a los Servicios Financieros, organizado por el Banco de España el 17 de junio de 2022, y las referencias a la bibliografía más reciente encontrada sobre el tema. La estructura del documento es la siguiente. En el epígrafe 2 se revisa el uso de ML en determinados campos de los servicios financieros. En el epígrafe 3 se recogen algunas de las cuestiones y retos que se plantean a la hora de implementar modelos de ML, y, finalmente, en el epígrafe 4 se concluye con una propuesta para la correcta aplicación de estas técnicas en el ámbito económico-financiero.

5 Por ejemplo, Albanesi y Vamosy (2019).

6 Véase Gan, Wang y Yang (2020).

7 Véanse Instituto de Finanzas Internacionales (2019a y 2020), Dupont, Fliche y Yang (2020) o BaFin (2021).

2 La transformación digital de los servicios financieros

Encuestas e informes recientes muestran que las entidades del ecosistema financiero, como bancos, aseguradoras, gestoras de activos y otros intermediarios, están usando cada vez más modelos de ML en diversas facetas de su negocio⁸. Notablemente, esta transformación se extiende más allá de los agentes financieros tradicionales, llegando a *hedge funds* o bancos de inversión, e incluso dando lugar al nacimiento de nuevas empresas (*fintech*) cuyo negocio reside en el dominio de esta tecnología para usarla en la provisión de servicios financieros⁹, lo cual ha contribuido a acelerar el ritmo de transformación tecnológica en el sector financiero¹⁰.

Para identificar las diferentes áreas en las que se está implementando el ML en las finanzas podemos recurrir a diversas revisiones sistemáticas de la literatura académica¹¹. De este modo, localizamos cinco grandes áreas donde predomina el uso de ML: 1) riesgo de crédito y decisión sobre la concesión de préstamos; 2) prevención del fraude y detección de anomalías; 3) predicción de variables económicas y financieras; 4) gestión de carteras y valoración de activos, y 5) gestión y trato con los clientes bancarios (por ejemplo, a través del uso de *chatbots*). No obstante, por su relevancia potencial y nivel de uso actual por parte de las entidades financieras, esta sección se centrará en las tres primeras¹².

Comenzando por la concesión de crédito, esta es un área donde existe consenso acerca del potencial beneficio derivado del uso de ML, ya que puede lograr una predicción más precisa respecto de los posibles impagos¹³. Además, las características particulares de las bases de datos de crédito¹⁴ las hacen especialmente propicias para usar modelos no paramétricos y no lineales, como las redes neuronales¹⁵, o los basados en la combinación de árboles de decisión¹⁶. Sin embargo, el uso de estos modelos conlleva una preocupación adicional relacionada con el potencial impacto que pudieran tener, ya sea en términos de sesgos y discriminación o por cuestiones de interpretabilidad, como veremos en la siguiente sección¹⁷.

-
- 8 Véanse Jung *et al.* (2019), que contiene un resumen del uso de ML en el sistema financiero del Reino Unido, e Instituto de Finanzas Internacionales (2019b) para una visión a escala internacional.
- 9 Véase Lynn *et al.* (2019).
- 10 Véase Eccles *et al.* (2021).
- 11 Por ejemplo, véanse Prado (2018) o Goodell *et al.* (2021).
- 12 Por ejemplo, según Instituto de Finanzas Internacionales (2019), entre las entidades que respondieron a la encuesta, las tres primeras aplicaciones con puestas en producción de modelos de ML fueron en *credit scoring* (37%), *credit monitoring* (25%) y *restructuring and recovery* (22%).
- 13 Véase Fuster *et al.* (2022).
- 14 En concreto, disponer de muchos datos de sección cruzada y ofrecer un gran número de variables explicativas con presencia de relaciones no lineales y con casos de impago poco frecuentes (variable explicativa desbalanceada).
- 15 En esta línea, Warin y Stojkov (2021) hacen un repaso de más de dos décadas del uso de técnicas de aprendizaje profundo en finanzas.
- 16 Véanse Huang *et al.* (2020) o Alonso-Robisco y Carbó Martínez (2022) como ejemplos de aplicaciones de modelos de *random forest* o XGBoost.
- 17 Véanse Barruetabeña (2020) para un resumen sobre digitalización e inclusión financiera, o Akinwumi *et al.* (2021), donde se recoge una guía de recomendaciones para las autoridades financieras americanas en torno a la provisión justa de crédito.

El área relacionada con la administración y gestión de riesgos, dentro de la cual se englobarían la prevención del fraude y el control del blanqueo de capitales, es probablemente donde más se ha extendido la puesta en producción de modelos de ML¹⁸. Los sistemas tradicionales de detección de fraude se basaban en el establecimiento de una serie de reglas estáticas, apoyadas luego por la opinión de expertos. Si bien estas técnicas no han tenido alternativa durante muchos años, el actual proceso de digitalización, que permite procesar mayor cantidad de información, unido a una mayor complejidad en los patrones de pagos y transferencias debido a la diversidad en los medios de pago, configura un escenario propicio para el uso de técnicas de ML. Así, la automatización de tareas o la reducción de falsos positivos son aspectos que permiten al ML ofrecer un mejor comportamiento. Inicialmente, el uso de estas técnicas se popularizó en la detección del fraude en el sector seguros, y se extendió posteriormente a la detección de anomalías en el sector corporativo y minorista (tarjetas de crédito)¹⁹. De hecho, las aplicaciones pueden ir más allá del contexto de los pagos y transacciones, como muestra un estudio reciente centrado en la manipulación del euríbor, usando modelos como redes neuronales para la detección de comportamientos anómalos en la fijación de este tipo de referencia²⁰.

Por último, una de las áreas donde la disponibilidad de grandes cantidades de datos es cada vez mayor es la de la producción de predicciones robustas de variables económicas y financieras, como el retorno de acciones o de índices de referencia de renta variable o el tipo de cambio, que ofrecen la posibilidad de obtenerlas en tiempo real²¹. Por ello, el uso de ML en series temporales es un campo de investigación en auge; destaca, principalmente, su contribución en dos áreas²². Primero, en modelos paramétricos de naturaleza estructural, donde es necesario obtener unos coeficientes de comportamiento y en los que estas técnicas pueden ayudar a regularizar y reducir la dimensión del conjunto de variables²³. En segundo lugar, existen técnicas orientadas a la predicción en modelos no paramétricos, como son las redes neuronales o aquellas basadas en la combinación de árboles de decisión²⁴. Actualmente, los resultados en este campo son prometedores, pero limitados, pues se basan en asunciones como la independencia de los datos, y se está explorando su comportamiento en entornos donde los regímenes que gobiernan los datos son cambiantes.

¹⁸ Véase Jung *et al.* (2019).

¹⁹ En Ngai *et al.* (2011) se hace una revisión inicial de la literatura de uso de modelos de *data mining* (incluyendo redes neuronales) para la prevención del fraude financiero.

²⁰ Véase Herrera *et al.* (2022).

²¹ Véase Richardson, Van Florenstein Mulder y Vehbi (2021) sobre su uso para *nowcasting*.

²² Véase una revisión de esta literatura en Masini, Medeiros y Mendes (2021).

²³ Por ejemplo, usando penalizaciones del tipo Lasso, Ridge o Elastic Net en regresiones lineales.

²⁴ Por ejemplo, *random forests* o *boosted trees*.

3 Una alianza estratégica

Como se ha mencionado anteriormente, la principal diferencia entre la econometría tradicional y el ML es que la primera supone que los datos son generados por un modelo estocástico asumido, mientras que el segundo usa modelos algorítmicos y trata el mecanismo de datos como desconocido. Esto permite a los modelos econométricos contrastar de modo relativamente directo relaciones de causalidad entre las variables en modelos estructurales, algo que en el caso del ML es aún un campo en pleno desarrollo²⁵. Por otro lado, los modelos de ML, siendo más complejos y difíciles de interpretar, proporcionan en muchas ocasiones mayor precisión en sus predicciones. En este contexto, suele presentarse la siguiente disyuntiva: ¿cuándo y cómo debemos usar ML?

3.1 Fortaleza: la precisión

Como se ha comentado, la precisión en la predicción es uno de los principales motivos para la adopción de ML. En algunos de los casos de uso mencionados en la sección anterior, como la prevención del fraude o el diseño de alertas tempranas por posible impago de deudores, el uso de ML comienza a ser habitual en el sistema financiero²⁶. Estos casos de uso tienen varias características en común, como la gran cantidad disponible de datos o la existencia de no linealidades en el comportamiento de los datos. Por otro lado, dado que la prioridad es la identificación temprana del suceso que se ha de identificar, y no tanto conocer los factores subyacentes que explican su aparición, se trata de contextos en los que los beneficios de usar ML resultan evidentes.

A pesar de que el uso de ML requiere trabajos adicionales en la preparación y análisis de los datos o en la revisión posterior de los resultados, la evidencia apunta a que cada vez más entidades están probando esta tecnología²⁷. La precisión se ha convertido en un elemento competitivo de importancia para las entidades, y ello requiere en ocasiones abandonar los modelos estadísticos tradicionales y probar nuevos enfoques innovadores²⁸. Adicionalmente, la irrupción de grandes empresas tecnológicas (*bigtech*), líderes en la utilización de este tipo de herramientas predictivas, cuyo uso en áreas o servicios puramente financieros se encuentra actualmente en exploración, aumenta la presión competitiva para usar estos modelos²⁹.

3.2 Debilidad: la interpretabilidad

A pesar de su beneficio en términos de mayor capacidad de predicción, la puesta en producción de modelos de ML en el sector financiero debe afrontar el reto de la dificultad para interpretar sus resultados (es decir, «cajas negras»), algo que en determinadas aplicaciones económicas puede ser un aspecto de especial relevancia. Un ejemplo de

²⁵ Véase Kaddour *et al.* (2022).

²⁶ Véase Jung *et al.* (2019).

²⁷ Véase Instituto de Finanzas Internacionales (2019b).

²⁸ Véase Königstorfer y Thalmann (2020) para una revisión de esta literatura académica.

²⁹ Véase Gorjón (2021).

estos casos es la concesión de préstamos, donde la regulación existente tanto en Estados Unidos como en Europa obliga a las entidades a explicar al usuario la razón por la cual se le otorga o deniega un préstamo³⁰. En un modelo econométrico tradicional, al imponerse una relación teórica subyacente, resulta más sencillo explicar la contribución de cada variable en los resultados de la predicción, algo que en el caso de los algoritmos de IA o ML es mucho más complejo. Esta opacidad es un importante obstáculo para su uso generalizado, sobre todo en actividades reguladas, y constituye una importante preocupación tanto para la industria financiera como para las autoridades financieras³¹. En este sentido, puede verse la importancia de este tema en las recientes consultas de Autoridad Bancaria Europea (2021) sobre el uso de ML en modelos IRB de capital regulatorio, o de BaFIN (2021) sobre el uso de ML en procesos de toma de decisiones.

Para abordar este problema, autoridades prudenciales como la francesa ACPR están desarrollando entornos de pruebas específicos para testear el desarrollo de herramientas de interpretabilidad aplicados a los modelos de ML, buscando en última instancia la sostenibilidad de estos modelos en entornos reales³². Este tipo de herramientas, cuyo uso es todavía incipiente, comienzan a establecerse como un campo de investigación específico denominado *explainable AI*³³ y no resulta exento de polémica tanto por su grado de fiabilidad en entornos especialmente sensibles (por ejemplo, las decisiones de crédito)³⁴ como por su capacidad para satisfacer los requerimientos de causalidad que exigen las autoridades financieras en general³⁵.

3.3 Un debate abierto

En resumen, existen áreas en las que las ventajas de usar ML son más claras, como es el caso de la prevención del fraude, y otras donde la interpretabilidad de los resultados es un claro obstáculo, como en las investigaciones económicas sobre predicción macroeconómica o la simulación de políticas, pues es clave conocer la razón que se encuentra detrás de las predicciones. Sin embargo, hay áreas con claroscuros, como es el caso de la concesión del crédito, donde la interpretabilidad es un factor importante, pero también la precisión, dado que una mayor precisión puede tener un gran impacto en la eficiencia del proceso de concesión de crédito³⁶.

Debemos recordar que la decisión de usar técnicas de ML para complementar o incluso sustituir modelos tradicionales no solo depende de la importancia que en cada contexto tengan la precisión y la interpretabilidad, sino también de otros factores, como el

30 En Europa podemos hacer referencia a la Directiva de Inteligencia Artificial [Comisión Europea (2021)], y en Estados Unidos las principales legislaciones en torno a la justicia en la concesión de crédito son *Equal Credit Opportunity Act* y *Fair Credit Reporting Act*. En cuanto al riesgo de modelo, se suele hacer referencia a la *Federal Reserve Board's Supervisory & Regulation Letter 11-7*.

31 Véase Instituto de Finanzas Internacionales (2020).

32 Véase Dupont (2022).

33 Véase Molnar (2020) para un mayor detalle sobre este campo de investigación.

34 Véase un ejemplo aplicado a la concesión de crédito en Alonso Robisco y Carbó (2022).

35 Véanse Rudin (2019) o Wachter, Mittelstadt y Russell (2017).

36 Véase Bono, Croxson y Giles (2021).

coste de implementación. El coste de poner en producción modelos de ML puede verse condicionado por la capacidad del usuario para preprocesar y controlar los datos que se usan (como, por ejemplo, detectar sesgos), la definición de la arquitectura del algoritmo, la comprobación de la estabilidad de este y la fiabilidad³⁷. Además, las ventajas del uso de ML pueden verse reducidas cuando las series que se han de predecir no contienen datos masivos (como es el caso de datos con periodicidad mensual o anual) ni cientos de variables explicativas³⁸. Por otra parte, el uso de econometría tradicional implica también un coste de implementación significativo, como puede ser el esfuerzo en obtener muestras de datos representativas, justificar el modelo teórico subyacente, identificar las variables explicativas más relevantes y contrastar las hipótesis con instrumentos estadísticos robustos. Por tanto, es necesario valorar el grado de adecuación de la formación de los empleados que usan estas herramientas cuantitativas, dadas las diferencias en los perfiles profesionales requeridos en ambos casos.

Por último, hay que destacar que, de modo incipiente, comienzan a desarrollarse propuestas que tratan de combinar ML y econometría. Por ejemplo, un enfoque consiste en utilizar en una primera etapa algún tipo de modelo basado en ML para construir una nueva variable explicativa con información adicional para incluir en una segunda etapa en un modelo de econometría tradicional³⁹. Otros estudios tratan de usar un número de variables limitado, pero de elevada importancia, permitiéndose la transformación de las series de datos de forma que respeten las teorías económicas subyacentes, y aplicar un modelo de ML para aprovechar sus ventajas no lineales y no paramétricas, pero con alguna restricción⁴⁰. Esta alianza estratégica es el fundamento del campo de investigación denominado *causal ML* o «aprendizaje automático causal», que, como dijimos, se encuentra en pleno desarrollo⁴¹. En esta línea, comienzan a salir estudios con aplicación en economía, que tratan de usar técnicas de interpretabilidad en conjunción con inferencia estadística tradicional sobre los valores de la importancia estimada de las variables⁴². Aunque los resultados de estos trabajos todavía son iniciales, incluso a escala académica, es un área a la que habrá que prestar especial atención en los próximos años.

37 Véase Unceta, Nin y Pujol (2020).

38 No obstante, trabajos como Fouliard, Howell y Rey (2021) buscan mejorar este aspecto, en concreto, para la predicción de crisis económicas usando técnicas de aprendizaje automático *online*, y obtienen resultados satisfactorios.

39 Rey Blanco *et al.* (2022) usan un clasificador basado en árboles de decisión para obtener información adicional que se utilizará en un modelo de econometría espacial para la valoración de inmuebles.

40 Este es el caso de Medeiros *et al.* (2021), que usan un modelo paramétrico para encontrar las variables significativas, para posteriormente predecir la inflación con un modelo que combina diversos árboles de decisión.

41 Véase Pearl y Mackenzie (2018) como trabajo seminal en esta área.

42 Véanse Joseph (2019) y Bluwstein *et al.* (2021).

4 Conclusiones

El uso de ML se está extendiendo en la economía y las finanzas por las recientes mejoras en la tecnología. Es un cambio de paradigma con respecto a los modelos de inferencia estadística y econometría tradicionales. Si bien estos modelos predicen mejor en algunos contextos, lo cierto es que también traen nuevos desafíos, entre ellos la complejidad de interpretar sus resultados. Por ello surgen algunos debates en torno a su uso y potencial puesta en práctica en entornos de producción real. En primer lugar, aunque existen técnicas que permiten la interpretación de los modelos de ML, hay dudas acerca de su fiabilidad y grado de madurez, y es complicado que se llegue al nivel de comprensión que se alcanza con técnicas más tradicionales basadas en un modelo subyacente (que puede ser o no correcto). En cualquier caso, la interpretabilidad o explicabilidad tienen distinto valor en función del contexto, como también lo tiene la precisión de la predicción o la capacidad de anticipar determinados comportamientos. Por ello es necesario identificar y valorar las ganancias y pérdidas que surgen en función de las técnicas utilizadas, sin descartar la posibilidad de combinar o complementar ambos enfoques.

En definitiva, nos encontramos ante una situación en la que los modelos tradicionales econométricos usados en los servicios financieros y en la economía pueden complementarse y, en ciertos casos, sustituirse con técnicas provenientes de la IA, las cuales se pueden implementar gracias a la disponibilidad de más información y la mejora computacional. La convivencia entre ambos tipos de modelos no es evidente y, en cualquier caso, debe tener en cuenta los avances que, a escala tanto académica como empírica, se están produciendo en cuestiones como las técnicas de interpretabilidad o las propuestas de nuevos modelos que tratan de conjugar las virtudes de ambos enfoques (destacan el control sobre las relaciones que gobiernan las variables y la precisión de las estimaciones). Adicionalmente, el uso de estas nuevas técnicas plantea nuevas áreas de riesgo que conviene tener en cuenta, y que tanto la normativa financiera como la regulación más general están considerando para permitir un aprovechamiento de sus beneficios que garantice valores fundamentales como la ausencia de discriminación basada en cuestiones de raza, sexo o religión o el respeto a la privacidad, a la vez que posibilite el aprovechamiento de los ciudadanos de los beneficios derivados del progreso tecnológico.

Bibliografía

- Akinwumi, M., J. Merrill, L. Rice, K. Salehy y M. Yap (2021). «An AI fair lending policy agenda for the federal financial regulators», *Economic Studies at Brookings*, 2 de diciembre.
- Albanesi, S., y D. F. Vamosy (2019). *Predicting consumer default: A deep learning approach*, Working Paper n.º 26165, National Bureau of Economic Research.
- Alonso, A., y J. M. Carbó (2022). *Accuracy of explanations of machine learning models for credit decisions*, Documentos de Trabajo, n.º 2222, Banco de España.
- Alonso Robisco, A., y J. M. Carbó Martínez (2022). «Measuring the model risk-adjusted performance of machine learning algorithms in credit default prediction», *Financial Innovation*, 8(1), pp. 1-35.
- Athey, S., y G. W. Imbens (2019). «Machine learning methods that economists should know about», *Annual Review of Economics*, 11, pp. 685-725.
- Autoridad Bancaria Europea (2021). *EBA Discussion Paper on Machine Learning for IRB Models*, EBA/DP/2021/04, 11 de noviembre.
- BaFin (2021). *Big data and artificial intelligence: Principles for the use of algorithms in decision-making processes*, BaFin Federal Financial Supervisory Authority, junio.
- Barruetaña, E. (2020). «La influencia de las nuevas tecnologías en la inclusión financiera», Artículos Analíticos, *Boletín Económico*, 1/2020, Banco de España.
- Bluwstein, K., M. Buckmann, A. Joseph, S. Kapadia y Ö. Simsek (2021). *Credit growth, the yield curve and financial crisis prediction: evidence from a machine learning approach*.
- Bono, T., K. Croxson y A. Giles (2021). «Algorithmic fairness in credit scoring», *Oxford Review of Economic Policy*, 37(3), pp. 585-617.
- Breiman, L. (2001). «Statistical modeling: The two cultures (with comments and a rejoinder by the author)», *Statistical Science*, 16(3), pp. 199-231.
- Comisión Europea (2021). *Proposal for a regulation of the European Parliament and the Council laying down harmonised rules on Artificial Intelligence (Artificial Intelligence Act) and amending certain Union legislative acts*, EUR-Lex-52021PC0206.
- Dupont, L. (2022). *ACPR Tech Sprint on the explainability of artificial intelligence*, Banco de Francia.
- Dupont, L., O. Fliche y S. Yang (2020). *Governance of Artificial Intelligence in Finance*, Banco de Francia.
- Eccles, P., P. Grout, P. Siciliani y A. A. Zalewska (2021). *The impact of machine learning and big data on credit markets*.
- Fouliard, J., M. Howell y H. Rey (2021). *Answering the queen: Machine learning and financial crises*, Working Paper n.º 28302, National Bureau of Economic Research.
- Fuster, A., P. Goldsmith-Pinkham, T. Ramadorai y A. Walther (2022). «Predictably unequal? The effects of machine learning on credit markets», *The Journal of Finance*, 77(1), pp. 5-47.
- Gan, L., H. Wang y Z. Yang (2020). «Machine learning solutions to challenges in finance: An application to the pricing of financial products», *Technological Forecasting and Social Change*, 153, 119928.
- Gimeno, R., y J. M. Marqués (2022). «Tradición e inteligencia artificial: oportunidades y retos del machine learning para los servicios financieros», *Revista Económica ICE*, vol. 926.
- Goodell, J. W., S. Kumar, W. M. Lim y D. Pattnaik (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.
- Gorjón, S. (2021). «Las grandes tecnológicas y los servicios financieros: algunos desafíos, beneficios y respuestas regulatorias», Artículos Analíticos, *Boletín Económico*, 4/2021, Banco de España.
- Herrera, R., F. Climent, P. Carmona y A. Momparler (2022). «The manipulation of Euribor: An analysis with machine learning classification techniques», *Technological Forecasting and Social Change*, 176, 121466.
- Huang, Y., L. Zhang, Z. Li, H. Qiu, T. Sun y X. Wang (2020). *Fintech Credit Risk Assessment for SMEs: Evidence from China*, IMF Working Papers, n.º 193.
- Instituto de Finanzas Internacionales (2019a). *Machine Learning: recommendations for policymakers*.
- Instituto de Finanzas Internacionales (2019b). *Machine learning in credit risk*.
- Instituto de Finanzas Internacionales (2020). *Machine learning governance*.
- Joseph, A. (2019). *Parametric inference with universal function approximators*, arXiv preprint arXiv:1903.04209.
- Jung, C., H. Mueller, S. Pedemonte, S. Plances y O. Thew (2019). *Machine learning in UK financial services*, Banco de Inglaterra y Financial Conduct Authority.
- Kaddour, J., A. Lynch, Q. Liu, M. J. Kusner y R. Silva (2022). *Causal Machine Learning: A Survey and Open Problems*, arXiv preprint arXiv:2206.15475.
- Königstorfer, F., y S. Thalmann (2020). «Applications of Artificial Intelligence in commercial banks-A research agenda for behavioral finance», *Journal of Behavioral and Experimental Finance*, 27, 100352.

- Lynn, T., J. G. Mooney, P. Rosati y M. Cummins (2019). «Disrupting finance: FinTech and strategy in the 21st century», *Springer Nature*, p. 175.
- Masini, R. P., M. C. Medeiros y E. F. Mendes (2021). «Machine learning advances for time series forecasting», *Journal of Economic Surveys*.
- Medeiros, M. C., G. F. Vasconcelos, Á. Veiga y E. Zilberman (2021). «Forecasting inflation in a data-rich environment: the benefits of machine learning methods», *Journal of Business & Economic Statistics*, 39(1), pp. 98-119.
- Molnar, C. (2020). *Interpretable machine learning*, Lulu.com.
- Ngai, E. W., Y. Hu, Y. H. Wong, Y. Chen y X. Sun (2011). «The application of data mining techniques in financial fraud detection: A classification framework and an academic review of literature», *Decision Support Systems*, 50(3), pp. 559-569.
- Pearl, J., y D. Mackenzie (2018). *The book of why: the new science of cause and effect*, Basic Books.
- Prado, M. L. de (2018). *Advances in financial machine learning*, John Wiley & Sons.
- Rey Blanco, D., P. González Arbués, F. López y A. Páez (2022). *Using machine learning to identify spatial market segments: a reproducible study of major Spanish markets*.
- Richardson, A., T. van Florenstein Mulder y T. Vehbi (2021). «Nowcasting GDP using machine-learning algorithms: A real-time assessment», *International Journal of Forecasting*, 37(2), pp. 941-948.
- Rudin, C. (2019). «Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead», *Nature Machine Intelligence*, 1(5), pp. 206-215.
- Unceta, I., J. Nin y O. Pujol (2020). «Copying machine learning classifiers», *IEEE Access*, 8, 160268-160284.
- Varian, H. R. (2014). «Big data: New tricks for econometrics», *Journal of Economic Perspectives*, 28(2), pp. 3-28.
- Yeung, K. (2020). «Recommendation of the council on artificial intelligence (OECD)», *International Legal Materials*, 59(1), pp. 27-34.
- Wachter, S., B. Mittelstadt y C. Russell (2017). «Counterfactual explanations without opening the black box: Automated decisions and the GDPR», *Harv. JL & Tech.*, 31, p. 841.
- Warin, T., y A. Stojkov (2021). «Machine Learning in Finance: A Metadata-Based Systematic Review of the Literature», *Journal of Risk and Financial Management*, 14(7), p. 302.

PUBLICACIONES DEL BANCO DE ESPAÑA

DOCUMENTOS OCASIONALES

- 2110 DMITRY KHAMETSHIN: High-yield bond markets during the COVID-19 crisis: the role of monetary policy.
- 2111 IRMA ALONSO y LUIS MOLINA: A GPS navigator to monitor risks in emerging economies: the vulnerability dashboard.
- 2112 JOSÉ MANUEL CARBÓ y ESTHER DIEZ GARCÍA: El interés por la innovación financiera en España. Un análisis con Google Trends.
- 2113 CRISTINA BARCELÓ, MARIO IZQUIERDO, AITOR LACUESTA, SERGIO PUENTE, ANA REGIL y ERNESTO VILLANUEVA: Los efectos del salario mínimo interprofesional en el empleo: nueva evidencia para España.
- 2114 ERIK ANDRES-ESCAIOLA, JUAN CARLOS BERGANZA, RODOLFO CAMPOS y LUIS MOLINA: A BVAR toolkit to assess macrofinancial risks in Brazil and Mexico.
- 2115 ÁNGEL LUIS GÓMEZ y ANA DEL RÍO: El impacto desigual de la crisis sanitaria sobre las economías del área del euro en 2020. (Existe una versión en inglés con el mismo número).
- 2116 FRUCTUOSO BORRALLO EGEEA y PEDRO DEL RÍO LÓPEZ: Estrategia de política monetaria e inflación en Japón. (Existe una versión en inglés con el mismo número).
- 2117 MARÍA J. NIETO y DALVINDER SINGH: Incentive compatible relationship between the ERM II and close cooperation in the Banking Union: the cases of Bulgaria and Croatia.
- 2118 DANIEL ALONSO, ALEJANDRO BUESA, CARLOS MORENO, SUSANA PÁRRAGA y FRANCESCA VIANI: Medidas de política fiscal adoptadas a partir de la segunda ola de la crisis sanitaria: área del euro, Estados Unidos y Reino Unido. (Existe una versión en inglés con el mismo número).
- 2119 ROBERTO BLANCO, SERGIO MAYORDOMO, ÁLVARO MENÉNDEZ y MARISTELA MULINO: El impacto de la crisis del COVID-19 sobre la vulnerabilidad financiera de las empresas españolas. (Existe una versión en inglés con el mismo número).
- 2120 MATÍAS PACCE, ISABEL SÁNCHEZ y MARTA SUÁREZ-VARELA: El papel del coste de los derechos de emisión de CO₂ y del encarecimiento del gas en la evolución reciente de los precios minoristas de la electricidad en España. (Existe una versión en inglés con el mismo número).
- 2121 MARIO ALLOZA, JAVIER ANDRÉS, PABLO BURRIEL, IVÁN KATARYNIUK, JAVIER J. PÉREZ y JUAN LUIS VEGA: La reforma del marco de gobernanza de la política fiscal de la Unión Europea en un nuevo entorno macroeconómico. (Existe una versión en inglés con el mismo número).
- 2122 MARIO ALLOZA, VÍCTOR GONZÁLEZ-DÍEZ, ENRIQUE MORAL-BENITO y PATROCINIO TELLO-CASAS: El acceso a servicios en la España rural. (Existe una versión en inglés con el mismo número).
- 2123 CARLOS GONZÁLEZ PEDRAZ y ADRIAN VAN RIXTEL: El papel de los derivados en las tensiones de los mercados durante la crisis del COVID-19. (Existe una versión en inglés con el mismo número).
- 2124 IVÁN KATARYNIUK, JAVIER PÉREZ y FRANCESCA VIANI: (De-)Globalisation of trade and regionalisation: a survey of the facts and arguments.
- 2125 BANCO DE ESPAÑA STRATEGIC PLAN 2024: RISK IDENTIFICATION FOR THE FINANCIAL AND MACROECONOMIC STABILITY: How do central banks identify risks? A survey of indicators.
- 2126 CLARA I. GONZÁLEZ y SOLEDAD NÚÑEZ: Markets, financial institutions and central banks in the face of climate change: challenges and opportunities.
- 2127 ISABEL GARRIDO: La visión del Fondo Monetario Internacional sobre la equidad en sus 75 años de vida. (Existe una versión en inglés con el mismo número).
- 2128 JORGE ESCOLAR y JOSÉ RAMÓN YRIBARREN: Las medidas del Banco Central Europeo y del Banco de España contra los efectos del COVID-19 en el marco de los activos de garantía de política monetaria y su impacto en las entidades españolas. (Existe una versión en inglés con el mismo número).
- 2129 BRINDUSA ANGHEL, AITOR LACUESTA y FEDERICO TAGLIATI: Encuesta de Competencias Financieras en las Pequeñas Empresas 2021: principales resultados. (Existe una versión en inglés con el mismo número).
- 2130 PABLO HERNÁNDEZ DE COS: Comparecencias ante la Comisión de Presupuestos del Congreso de los Diputados, el 25 de octubre de 2021, y ante la Comisión de Presupuestos del Senado, el 30 de noviembre de 2021, en relación con el Proyecto de Presupuestos Generales del Estado para 2022. (Existe una versión en inglés con el mismo número).
- 2131 LAURA AURIA, MARKUS BINGMER, CARLOS MATEO CAICEDO GRACIANO, CLÉMENCE CHARAVEL, SERGIO GAVILÁ, ALESSANDRA IANNAMORELLI, AVIRAM LEVY, ALFREDO MALDONADO, FLORIAN RESCH, ANNA MARIA ROSSI y STEPHAN SAUER: Overview of central banks' in-house credit assessment systems in the euro area.

- 2132 JORGE E. GALÁN: CREWS: a CAMELS-based early warning system of systemic risk in the banking sector.
- 2133 ALEJANDRO FERNÁNDEZ CERESO y JOSÉ MANUEL MONTERO: Un análisis sectorial de los retos futuros de la economía española.
- 2201 MANUEL A. PÉREZ ÁLVAREZ: Nueva asignación de derechos especiales de giro. (Existe una versión en inglés con el mismo número).
- 2202 PILUCA ALVARGONZÁLEZ, MARINA GÓMEZ, CARMEN MARTÍNEZ-CARRASCAL, MYROSLAV PIDKUYKO y ERNESTO VILLANUEVA: Analysis of labor flows and consumption in Spain during COVID-19.
- 2203 MATÍAS LAMAS y SARA ROMANIEGA: Elaboración de un índice de precios para el mercado inmobiliario comercial de España. (Existe una versión en inglés con el mismo número).
- 2204 ÁNGEL IVÁN MORENO BERNAL y TERESA CAMINERO GARCÍA: Analysis of ESG disclosures in Pillar 3 reports. A text mining approach.
- 2205 OLYMPIA BOVER, LAURA CRESPO y SANDRA GARCÍA-URIBE: El endeudamiento de los hogares en la Encuesta Financiera de las Familias y en la Central de Información de Riesgos: un análisis comparativo. (Existe una versión en inglés con el mismo número).
- 2206 EDUARDO GUTIÉRREZ, ENRIQUE MORAL-BENITO y ROBERTO RAMOS: Dinámicas de población durante el COVID-19. (Existe una versión en inglés con el mismo número).
- 2207 JULIO GÁLVEZ: Measuring the equity risk premium with dividend discount models.
- 2208 PILAR CUADRADO, MARIO IZQUIERDO, JOSÉ MANUEL MONTERO, ENRIQUE MORAL-BENITO y JAVIER QUINTANA: El crecimiento potencial de la economía española tras la pandemia. (Existe una versión en inglés con el mismo número).
- 2209 PANA ALVES, SERGIO MAYORDOMO y MANUEL RUIZ-GARCÍA: La financiación empresarial en los mercados de renta fija: la contribución de la política monetaria a mitigar la barrera del tamaño. (Existe una versión en inglés con el mismo número).
- 2210 PABLO BURRIEL, IVÁN KATARYNIUK y JAVIER J. PÉREZ: Computing the EU's SURE interest savings using an extended debt sustainability assessment tool.
- 2211 LAURA ÁLVAREZ, ALBERTO FUERTES, LUIS MOLINA y EMILIO MUÑOZ DE LA PEÑA: La captación de fondos en los mercados internacionales de capitales en 2021. (Existe una versión en inglés con el mismo número).
- 2212 CARLOS SANZ: El peso del sector público en la economía: resumen de la literatura y aplicación al caso español.
- 2213 LEONOR DORMIDO, ISABEL GARRIDO, PILAR L'HOTELLERIE-FALLOIS y JAVIER SANTILLÁN: El cambio climático y la sostenibilidad del crecimiento: iniciativas internacionales y políticas europeas. (Existe una versión en inglés con el mismo número).
- 2214 CARMEN SÁNCHEZ y JARA QUINTANERO: Las empresas *fintech*: panorama, retos e iniciativas.
- 2215 MARÍA ALONSO, EDUARDO GUTIÉRREZ, ENRIQUE MORAL-BENITO, DIANA POSADA, PATROCINIO TELLO-CASAS y CARLOS TRUCHARTE: La accesibilidad presencial a los servicios bancarios en España: comparación internacional y entre servicios. (Existe una versión en inglés con el mismo número).
- 2216 BEATRIZ GONZÁLEZ, ENRIQUE MORAL-BENITO e ISABEL SOLER: Schumpeter Meets Goldilocks: the Scarring Effects of Firm Destruction.
- 2217 MARIO ALLOZA, JÚLIA BRUNET, VÍCTOR FORTE-CAMPOS, ENRIQUE MORAL-BENITO y JAVIER J. PÉREZ: El gasto público en España desde una perspectiva europea.
- 2218 PABLO AGUILAR, BEATRIZ GONZÁLEZ y SAMUEL HURTADO: Carbon tax sectoral (CATS) model: a sectoral model for energy transition stress test scenarios.
- 2219 ALEJANDRO MUÑOZ-JULVE y ROBERTO RAMOS: Estimación del impacto de variaciones en el período de cálculo de la base reguladora sobre la cuantía de las nuevas pensiones de jubilación. (Existe una versión en inglés con el mismo número).
- 2220 LUIS ÁNGEL MAZA: Una estimación de la huella de carbono en la cartera de préstamos a empresas de las entidades de crédito en España. (Existe una versión en inglés con el mismo número).
- 2221 SUSANA MORENO SÁNCHEZ: The EU-UK relationship: regulatory divergence and the level playing field.
- 2222 ANDRÉS ALONSO-ROBISCO y JOSÉ MANUEL CARBÓ: Inteligencia artificial y finanzas: una alianza estratégica.