



Thierry Foucault, Leonardo Gambacorta,
Wei Jiang y Xavier Vives

Inteligencia artificial en
finanzas

CEPR

 **IESE**
Business School
University of Navarra

Banking
Initiative

INTELIGENCIA ARTIFICIAL EN FINANZAS

El futuro de la banca 7

[PRENSA CEPR](#)

Centro de Investigación de Política Económica

187 boulevard Saint-Germain

75007 París, Francia

2 Coldbath Square

Londres EC1R 5HL, Reino

Unido Tel.: +44 (20) 7183

8801 Fax: +44 (20) 7183

8820 Correo electrónico:

cepr@cepr.org Web: www.cepr.org

ISBN: 978-1-912179-93-0

© 2025 CEPR Press

INTELIGENCIA ARTIFICIAL EN FINANZAS

El futuro de la banca 7

Thierry Foucault
HEC Paris y CEPR

Leonardo Gambacorta
Banco de Pagos Internacionales y CEPR

Wei Jiang
Universidad Emory

Xavier Vives
IESE Business School y CEPR



With the support of Citi

CENTRE FOR
ECONOMIC
POLICY
RESEARCH

[CENTRO DE INVESTIGACIÓN DE POLÍTICA ECONÓMICA \(CEPR\)](#)

El Centro de Investigación de Política Económica (CEPR) es una red de casi 1900 economistas investigadores, ubicados principalmente en universidades europeas. Su objetivo es doble: promover la investigación de primer nivel y poner los resultados relevantes para la formulación de políticas en manos de los principales responsables de la toma de decisiones. El principio rector del CEPR es «Excelencia en la investigación con relevancia política». Se fundó en el Reino Unido en 1983, donde opera como organización benéfica. En noviembre de 2019, el CEPR inició la creación de una asociación de derecho francés para impulsar su expansión en Francia. Los miembros del Consejo de Administración de la Asociación son idénticos a los de la Junta Directiva del Reino Unido.

El CEPR es independiente de todos los grupos de interés públicos y privados. No adopta una postura institucional en materia de política económica y su principal fuente de financiación proviene de sus miembros institucionales, los proyectos que gestiona y la venta de sus publicaciones. Al contar con una amplia red de investigadores, su producción refleja un amplio espectro de puntos de vista individuales, así como perspectivas de la sociedad civil. La investigación del CEPR puede incluir opiniones sobre políticas, pero los miembros del Consejo de Administración de la Asociación no revisan previamente sus publicaciones. Las opiniones expresadas en este informe son las de los autores y no las del CEPR.

Presidente de la Junta Directiva	Señor Charlie Bean
Fundador y Presidente Honorario	Richard Portes
Presidente	Béatrice Weder di Mauro
Vicepresidentes	Maristella Botticini
	Antonio Fatás
	Ugo Panizza
	Helene Rey
Director ejecutivo	Tessa Ogden

[ESCUELA DE NEGOCIOS IESE](#)

El IESE es la escuela de negocios de posgrado de la Universidad de Navarra. Fundada en 1958, es una de las escuelas de negocios más internacionales del mundo, con campus en Barcelona, Madrid, Múnich, Nueva York y São Paulo. Constantemente clasificada entre las diez mejores del mundo, el IESE Business School ha sido pionero en la formación empresarial en Europa desde su fundación. Durante más de sesenta años, el IESE ha buscado formar líderes empresariales con sólidas habilidades empresariales, una mentalidad global y el deseo de generar un impacto positivo en las personas y la sociedad. La escuela se distingue por su enfoque de gestión general, el amplio uso del método del caso, su proyección internacional y su énfasis en situar a las personas en el centro de la toma de decisiones directivas.

Acerca de los autores

Thierry Foucault es catedrático de Finanzas en HEC París e investigador del CEPR. Tiene un doctorado en Finanzas por HEC París. Su investigación se centra en

El papel de la información en los mercados financieros, la organización industrial de estos mercados y su efecto en la economía real. Es coeditor del Journal of Financial and Quantitative Analysis y editor asociado del Journal of Finance. Forma parte de los comités científicos de la Autorité des marchés financiers (AMF) y del Programa Académico del Norges Bank. Es coautor de Market Liquidity: Theory, Evidence, and Policy (Oxford University Press).

Leonardo Gambacorta es el Jefe de la Unidad de Mercados Emergentes del BPI. Antes de su puesto actual, se desempeñó como Jefe de Innovación y Economía Digital (2019-2024), Asesor de Investigación (2014-2018) y Jefe de Política Monetaria (2010-2012) en el Departamento Monetario y Económico. Antes de incorporarse al BPI, fue Jefe de la Unidad de Dinero y Crédito (2007-2009) y Jefe de la Unidad del Sector Bancario (2004-2006) en el Departamento de Investigación del Banco de Italia. Fue profesor visitante en la Oficina Nacional de Investigación Económica (2002-2003). Leonardo tiene una Maestría en Economía de la Universidad de Warwick y un Doctorado en Economía de la Universidad de Pavia. Sus principales intereses de investigación incluyen los mecanismos de transmisión monetaria, la eficacia de las políticas macroprudenciales para frenar el riesgo sistémico y los efectos de la innovación tecnológica en la intermediación financiera. Es Investigador del Centro para

Investigación de política económica.

Wei Jiang es Profesora de Finanzas Asa Griggs Candler y Vicedecana de Facultad e Investigación en la Escuela de Negocios Goizueta de la Universidad de Emory. Es Investigadora Asociada del NBER. Es Presidenta Electa de la Asociación Americana de Finanzas (AFA) en 2025 y anteriormente fue Presidenta de la Sociedad de Estudios Financieros (SFS). Sus principales intereses de investigación son el gobierno corporativo, los inversores institucionales, la tecnología y los mercados financieros. Ha publicado extensamente en las principales revistas de economía, finanzas y derecho, y su investigación ha aparecido con frecuencia en los principales medios de comunicación. Ha recibido decenas de premios a la excelencia investigadora, incluyendo los premios al mejor artículo del Journal of Finance, Review of Financial Studies y Journal of Financial Economics. Anteriormente, fue editora de Review of Financial Studies, editora del Departamento de Finanzas de Management Science y editora asociada del Journal of Finance. La profesora Jiang se doctoró en Economía por la Universidad de Chicago en 2001 y se incorporó al profesorado de Finanzas de la Escuela de Negocios de Columbia ese mismo año. Fue profesora Arthur F. Burns de Empresa Libre y Competitiva en la Escuela de Negocios de Columbia hasta 2022.

Xavier Vives es Catedrático de Economía y Finanzas en IESE Business School.

Es miembro del Comité Científico Asesor de la JERS (BCE), Fellow de la Econometric Society desde 1992, de la Asociación Económica Europea desde 2004 y de la Academia Europaea desde 2012. Fue presidente de la Asociación Europea para la Investigación en Economía Industrial (EARIE) entre 2016 y 2018 y de la Asociación Europea de Finanzas en 2023. Fue Duisenberg Fellow del Banco Central Europeo en 2015.

Ha impartido docencia en INSEAD, la Universidad de Harvard, la Universidad Autónoma de Barcelona, la Universidad Pompeu Fabra, UC Berkeley, la Universidad de Pensilvania y la Universidad de Nueva York. Sus áreas de interés son la organización y regulación industrial, la banca y la economía financiera. Ha publicado más de cien artículos en las principales revistas internacionales y varios libros, el más reciente de los cuales es «Competition and Stability in Banking». Entre 2011 y 2014 fue asesor especial del comisario europeo de Competencia, Joaquín Almunia, y hasta mayo de 2020 fue consejero independiente principal de CaixaBank. Ha sido asesor del Banco Mundial, el Banco Interamericano de Desarrollo, la Comisión Europea y la Reserva Federal de Nueva York. Es doctor en Economía por UC Berkeley.

Expresiones de gratitud

Los autores se han beneficiado de los comentarios de los ponentes del informe en la conferencia del 20 de marzo de 2025, Diana Bonfim, Sean Cao, William Cong, Luca Enriques, Ronit Ghose y Robin Lumsdaine, así como de los participantes y moderadores de la conferencia, Luigi Guiso, Rafael Repullo y Victoria Vanasco. Agradecemos a los participantes de la mesa redonda, Bonnie Buchanan, Zanna Iscenko y Charles-Albert Lehalle, y un reconocimiento especial a José Luis Escrivá por su contribución en la inauguración de la conferencia.

vii

Thierry Foucault agradece a Markus Bak-Hansen, Maxime Bonelli, Eloi Foucault y Yuri Handziuk por sus comentarios y a Teodor Duevski por su ayuda en la investigación. Leonardo

Gambacorta agradece a In˜aki Aldasoro, Sarah Bell, Giulio Cornelli, Sebastian Doerr, Jon Frost, Fernando Perez Cruz, Han Qiu, Vatsala Shreeti y Hyun Song Shin. Wei Jiang está agradecido a Tucker Balch, Zhishuo Han, Tao Li, Will Mann y Baozhong Yang.

Xavier Vives agradece a Josep Gisbert su valiosa aportación al informe y a Joan Freixa su excelente asistencia en la investigación. Los autores también se beneficiaron de las ponencias presentadas en el Taller de la Iniciativa Bancaria del IESE, que precedió a la conferencia. Carlota Monner brindó un apoyo general muy eficiente.

Las opiniones expresadas en este informe son las de los autores. No deben interpretarse como representativas de ninguna institución con la que estén o hayan estado afiliados, ni de las personas mencionadas anteriormente.

Contenido

Acerca de los autores	v
Expresiones de gratitud	vii
Programa de la conferencia	—
Lista de participantes de la conferencia	xi
Programa del taller	xiii
Lista de participantes del taller	xiv
Prefacio	xvi
 Resumen ejecutivo	 1
 El impacto transformador de la inteligencia artificial en el sector financiero y los bancos centrales	 7
 por José Luis Escrivá Belmonte	
 1 Introducción	 13
1.1 Características y usos de la IA en las finanzas: ¿Qué es antiguo y qué es nuevo?	15
1.2 Inteligencia artificial y el sector financiero: Transformaciones, desafíos y respuestas regulatorias	17
1.3 Abundancia de datos, IA y mercados financieros: implicaciones y riesgos 1.4	23
Finanzas corporativas y gobernanza con IA: lo antiguo y lo nuevo 1.5	30
Conclusiones e implicaciones políticas Apéndice:	38
Construcción de la Figura 1	41
 2 Inteligencia artificial y el sector financiero: Transformaciones, desafíos y 43 respuestas regulatorias	
2.1 IA en finanzas: ¿Cuáles son las nuevas oportunidades?	44
2.2 IA en finanzas: Viejos problemas, nuevos desafíos 2.3	55
¿Cómo regular la IA?	65
2.4 Conclusiones	68
 3 El impacto de la IA en las finanzas: la reformulación de la información y sus consecuencias	 71
3.1 ¿Por qué la IA está reformulando la información financiera?	73
3.2 Implicaciones para la industria de valores 3.3	83
Riesgo	91
3.4 Conclusión: Implicaciones políticas	106
 4 Finanzas corporativas y gobernanza con inteligencia artificial: Lo antiguo y lo nuevo 109	
4.1 Introducción 4.2	109
Delegación a la IA: El problema de la agencia revisado 4.3 Las	113
caras cambiantes de la información y la asimetría de la información 4.5 Conclusión	123
	149
 Discusiones	 150
Referencias	177

Programa de la conferencia

IESE Business School, Campus de Barcelona

Viernes, 21 de marzo de 2025

09:15 Bienvenidos

Jordi Canals, IESE

Xavier Vives, IESE

Discurso inaugural: «El impacto transformador de la inteligencia artificial en el sector financiero y los bancos centrales».

José Luis Escrivá, Gobernador del Banco de España

09:45 IA y el sector financiero: transformaciones, desafíos y regulaciones

respuestas

Leonardo Gambacorta, Banco de Pagos Internacionales

Ponente 1: Diana Bonfim, Banco de Portugal, Católica Lisboa y CEPR

Comentarista 2: Ronit Ghose, Citi

Presidente: Luigi Guiso, Instituto Einaudi de Economía y Finanzas

10:45 Descanso

11:15 Finanzas corporativas y gobernanza con IA: Lo antiguo y lo nuevo

Wei Jiang, Universidad Emory

Comentarista 1: Sean Cao, Universidad de Maryland

Comentarista 2: Luca Enriques, Universidad Bocconi

Presidente: Rafael Repullo, CEMFI

12:15 Mesa redonda

Bonnie Buchanan, Centro de FinTech Sostenible y Explicable, Universidad de Surrey

Zanna Iscenko, Google

Charles-Albert Lehalle, Escuela Politécnica, IP-París

Presidente: Xavier Vives, IESE

13:15 Almuerzo

14:30 El impacto de la IA en los mercados financieros: las consecuencias de la evolución

Producción de información

Thierry Foucault, HEC París

Comentarista 1: William Cong, Universidad de Cornell

Comentarista 2: Robin Lumsdaine, Universidad Americana

Moderadora: Victoria Vanasco, CREI, UPF, BSE

15:30 Conclusión

16:00 Cierre de la reunión

Lista de participantes de la conferencia

Simona Abis	Universidad de Colorado en Boulder
Carmen Ansotegui	Escuela de Negocios ESADE
Tania Babina	Universidad de Maryland
Ana Bayona	Escuela de Negocios ESADE
Vicente Bermejo	Escuela de Negocios ESADE
Diana Bonfim	Banco de Portugal, Católica Lisboa y CEPR
Bonnie Buchanan	Centro SAEF FinTech, Universidad de Surrey
Jordi Canals	Escuela de Negocios IESE
Sean Cao	Universidad de Maryland
Madalen Castells	Banco Central Europeo
Che Chen	Escuela de Negocios IESE
Long Cheng	Escuela de Negocios IESE
Jean-Édouard Colliard	HEC París
Irem Demirci	Escuela Nova de Negocios y Economía
Olivier Dessaint	INSEAD
Luca Enriques	Universidad Bocconi
Thiago Favvrelle	Mecanismo Europeo de Estabilidad
Enric Fernández	Caixabank
Thierry Foucault	HEC París
Joan Freixa	Escuela de Negocios IESE
Xavier Freixas	Universidad Pompeu Fabra
Leonardo Gambacorta	Banco de Pagos Internacionales
Teresa García Milá	UPF y BSE
Ronit Ghose	Citi
Javier Gil Bazo	Universidad Pompeu Fabra
Mireia Giné	Escuela de Negocios IESE
Marco Girometti	Universidad Carlos III de Madrid
Josep Gisbert	Escuela de Negocios IE
Luigi Guiso	Instituto Einaudi de Economía y Finanzas
Min Fang Guo	Escuela de Negocios IESE
Sandro Harz	Fmals GmbH / INEOS
Zanna Iscenko	Google LLC
Lorenzo Isla	Caixabank
Jia Yichuan	Escuela de Negocios IESE
Wei Jiang	Universidad Emory
Binghan Jiang	PSL-Dauphine
Artashes Karapetyan	ESSEC
Enisse Kharroubi	Banco de Pagos Internacionales
Andréi Kirilenko	Universidad de Cambridge
Gael Le Mens	Universidad Pompeu Fabra

xii

REFERENCIAS

Mayte Ledo	Banco de España
Charles-Albert Lehalle	Escuela Politécnica, IP-París
Gyoengyi Loranth	Universidad de Viena
Jesús Lozano	BBVA
Robin Lumsdaine	Escuela de Negocios Kogod, Universidad Americana
Sameh Marei	Escuela de Negocios ESADE
Montserrat Martínez Parera	Banco de España
Carmen Matutes	Inversiones en forma de onda
Núria Mas	Escuela de Negocios IESE
Anna Maymús	Banco Sabadell
Roxana Mihet	Universidad de Lausana y SFI
Marta Pla	Banco Sabadell
Isaac Ré Delgado	Santander Asset Management
Rafael Repullo	CEMFI
Martín Rohar	Mecanismo Europeo de Estabilidad
Javier Santomá	Escuela de Negocios IESE
Stefano Schiaffi	Banco de Italia
Jörg Stahl	Universidad Católica Portuguesa
Gabriela Stockler	UPF y BSE
Javier Suárez	CEMFI
Andrew Sutton	GovAI / Iniciativa de Londres para una IA Segura (LISA)
Leonardo Tarifa	Universidad de Barcelona
Tammaro Terracciano	Escuela de Negocios IESE
Jaume Torrents	Caixabank
Patrick Trezise	Banco Sabadell
Antoine Uetwiller	Universidad Queen Mary de Londres
Victoria Vanasco	CREI, UPF, Barcelona GSE
Elena Vardón	Wall Street Journal / Dow Jones
Xavier Vives	Escuela de Negocios IESE
Michelle Wallin	Escuela de Negocios IESE
Haorui Wang	Escuela de Negocios IESE
hao yang	Instituto Suizo de Finanzas y USI Lugano
Liyan Yang	Universidad de Toronto
Zhiqiang Ye	Universidad de Zhejiang
Jiamin Zhao	Escuela de Negocios IESE

Programa del taller

IESE Business School, Campus de Barcelona

Jueves, 20 de marzo de 2025

xiii

09:15 Palabras de apertura

09:30 Primera Sesión, Moderador: Xavier Vives

1. "Trading impulsado por IA, colusión algorítmica y eficiencia de precios" (con I. Goldstein y Y. Ji)

Presentador: Winston Dou, Wharton School.

Comentarista: Hao Yang, Swiss Finance Institute y USI Lugano 2. "Precios algorítmicos y liquidez en los mercados de valores" (con T. Foucault y S. Lovo).

Presentador: Jean-Edouard Colliard, HEC Paris

Comentarista: Liyan Yang, Rotman School of Management

11:00 Descanso

11:30 Segunda sesión, Presidente: Thierry Foucault, HEC París

1. "Inteligencia artificial y riesgo sistemático en las empresas" (con A. Fedyk, A. He y J. Hodson)

Presentadora: Tania Babina, Escuela de Negocios de Columbia.

Comentarista: Simona Abis, Universidad de Colorado en Boulder. 2.

"Políticas de privacidad y extracción de datos de consumidores: evidencia de empresas estadounidenses" (con T. Ramadorai y A. Walther).

Presentador: Antoine Uetwiller, Queen Mary University of London Comentarista:

Mireia Giné, IESE

13:00 Almuerzo

14:00 Tercera sesión, Presidente: Wei Jiang, Universidad Emory 1. "IA

generativa y valores de la empresa" (con A. Eisfeldt y MB Zhang)

Presentador: Gregor Schubert, UCLA Anderson.

Comentarista: Olivier Dessaint, INSEAD. 2.

"Aprendizaje automático sobre opciones de capital riesgo" (con V. Lyonnet).

Presentadora: Léa H. Stern, Universidad de Washington.

Comentarista: Ramana Nanda, Imperial College London.

15:30 Descanso

16:00 Cuarta sesión, Presidente: Leonardo Gambacorta, BIS

1. "Complementariedad de la innovación de datos y crecimiento de las empresas" (con A. Fedyk, O. Gomes y K. Rishabh)

Presentadora: Roxana Mihet, Universidad de Lausana

Comentarista: Enisse Kharroubi, BIS 2.

"Inteligencia artificial y préstamos relacionales" (con L. Gambacorta y F. Sabatini)

Presentador: Stefano Schiaffi, Banco de Italia

Comentarista: Xavier Freixas, Universitat Pompeu Fabra

17:30

Cierre de la reunión

Lista de participantes del taller

xiv	Simona Abis	Universidad de Colorado en Boulder
	Carmen Ansotegui	Escuela de Negocios ESADE
	Tania Babina	Universidad de Maryland
	Ana Bayona	Escuela de Negocios ESADE
	Vicente Bermejo	Escuela de Negocios ESADE
	Diana Bonfim	Banco de Portugal, Católica Lisboa y CEPR
	Bonnie Buchanan	Centro SAEF FinTech, Universidad de Surrey
	Héctor Calvo-Pardo	Universidad de Southampton
	Sean Cao	Universidad de Maryland
	Madalen Castells	Banco Central Europeo
BIBLIOTECARIA	Che Chen	Escuela de Negocios IESE
	Long Cheng	Escuela de Negocios IESE
	Jean-Édouard Colliard	HEC París
	Irem Demirci	Escuela Nova de Negocios y Economía
	Olivier Dessaint	INSEAD
	Winston Dou	Escuela Wharton
	Christian Eufinger	Escuela de Negocios IESE
	Thiago Fauvreille	Mecanismo Europeo de Estabilidad (MEDE)
	Thierry Foucault	HEC París
	Joan Freixa	Escuela de Negocios IESE
	Xavier Freixas	Universidad Pompeu Fabra
	Leonardo Gambacorta	Banco de Pagos Internacionales
	Javier Gil Bazo	Universidad Pompeu Fabra
	Mireia Giné	Escuela de Negocios IESE
	Marco Giometti	Universidad Carlos III de Madrid
	Josep Gisbert	Escuela de Negocios IE
	Sandro Harz	Fmals GmbH / INEOS
	Jia Yichuan	Escuela de Negocios IESE
	Wei Jiang	Universidad Emory
	Binghan Jiang	PSL-Dauphine
	Enisse Kharroubi	Banco de Pagos Internacionales
	Dmitri Kuvshinov	Universidad Pompeu Fabra
	Gael Le Mens	Universidad Pompeu Fabra
	Yang Lou	Escuela de Negocios IESE
	Jesús Lozano	BBVA
	Robin Lumsdaine	Escuela de Negocios Kogod, Universidad Americana
	Emanuele Luzzi	Universidad Suiza Italiana Instituto Suizo de Finanzas
	Sameh Marei	Escuela de Negocios ESADE

Carmen Matutes	Inversiones en forma de onda
Roxana Mihet	Universidad de Lausana y SFI
Ramana Nanda	Imperial College de Londres
José Penalva	Universidad Carlos III
Marta Pla	Banco Sabadell
Isaac Ré Delgado	Santander Asset Management
Rafael Repullo	CEMFI
Marta Rivera	Banco Sabadell
Martín Rohar	Mecanismo Europeo de Estabilidad
Kristine Sahakyan	Escuela de Negocios ESCP
Stefano Schiaffi	Banco de Italia
Gregor Schubert	Escuela de Administración Anderson de la UCLA
Jörg Stahl	Universidad Católica Portuguesa
Gabriela Stockler	UPF y BSE
Javier Suárez	CEMFI
Andrew Sutton	GovAI / Iniciativa de Londres para una IA Segura (LISA)
Leonardo Tarifa	Universidad de Barcelona
Tammaro Terracciano	Escuela de Negocios IESE
Antoine Uetwiller	Universidad Queen Mary de Londres
Victoria Vanasco	CREI, UPF, Barcelona GSE
Xavier Vives	Escuela de Negocios IESE
Michelle Wallin	Escuela de Negocios IESE
Haorui Wang	Escuela de Negocios IESE
Xu Fangming	Universidad de Bristol
hao yang	Instituto Suizo de Finanzas y USI Lugano
Liyan Yang	Universidad de Toronto
Zhiqiang Ye	Universidad de Zhejiang

Prefacio

xvi

Este es el séptimo informe de la serie sobre El Futuro de la Banca, parte del informe Banking Initiative de la Escuela de Negocios IESE que se lanzó en octubre de 2018 y que está con el apoyo de Citi.

El objetivo de la Iniciativa Bancaria del IESE es establecer un grupo de investigadores de primer nivel para estudiar los nuevos desarrollos en la banca y los mercados financieros, con especial atención a la regulación y las políticas de competencia, así como a su impacto en los modelos de banca empresarial y el rendimiento de los mercados. Su objetivo es promover un diálogo riguroso e informado sobre temas de actualidad en el ámbito de la banca y los mercados financieros entre académicos, reguladores, empresas del sector privado y la sociedad civil.

RESILIENCIA

El primer informe, publicado en 2019, evaluó la reforma regulatoria del sistema bancario tras la Gran Recesión provocada por la crisis financiera mundial de 2008-2009 y sugirió que la próxima crisis mundial podría tener diferentes orígenes, posiblemente en entidades que desempeñan funciones bancarias pero están fuera del perímetro regulatorio, o en un mercado emergente donde la regulación podría ser distinta a los patrones reformados de Occidente. Concluyó que el sistema se había vuelto más resiliente, pero que aún quedaba trabajo por hacer.

El segundo informe abordó los cambios en los modelos de negocio de los bancos e identificó que los desafíos que enfrentaban antes de la COVID-19 —principalmente las bajas tasas de interés y la disrupción digital— se agravarán en el mundo pos-COVID. Los bancos han tenido que afrontar un aumento de la morosidad, si bien con un alivio temporal de la estricta regulación y una importante inyección de liquidez por parte de los bancos centrales. Esto ha acelerado la reestructuración del sector.

El tercer informe analizó las diferencias entre el riesgo climático y de desastres naturales y otras formas más comunes de riesgo financiero y económico, y cómo los bancos, gestores de activos y bancos centrales están empezando a abordar estos riesgos. La COVID-19 nos ha hecho conscientes del efecto potencialmente devastador de los desastres naturales y nos ofrece un indicio de los efectos que puede inducir el cambio climático. Al mismo tiempo, la crisis de la COVID-19 proporcionó un experimento natural a gran escala para abordar esta cuestión y situar los desastres naturales, ya sean pandemias o catástrofes climáticas, en la agenda de instituciones privadas, reguladores bancarios y bancos centrales.

El cuarto informe abordó el impacto de la tecnología en los mercados e instituciones financieras e identificó los desafíos en tres áreas específicas: sistemas de pago, uso de big data y negociación en los mercados. La tecnología digital ha planteado enormes desafíos para los intermediarios financieros, las empresas, las bolsas y los organismos reguladores.

Los problemas han sido la idoneidad de la moneda digital emitida por el banco central, las compensaciones que implica el uso masivo de datos en términos de eficiencia, privacidad y poder de mercado, y los cambios inducidos por la electronicización de los mercados financieros. Se cuestionó cómo equilibrar los aspectos positivos y negativos de la tecnología para fundamentar la regulación.

El quinto informe examinó las implicaciones de la pandemia de COVID-19 y la guerra en Ucrania para el orden económico y financiero internacional. Se centró en tres componentes principales: las perspectivas macroeconómicas y los cambios necesarios en el modelo de política económica (fiscal, monetaria y regulatoria) para preservar la estabilidad económica y financiera; las consecuencias para el sistema monetario internacional y la posición del dólar estadounidense; y la arquitectura financiera necesaria para garantizar la sostenibilidad de la deuda soberana, con especial atención a Europa. La conclusión general fue que la pandemia y la guerra han acelerado las tendencias previas, lo que revela posibles conflictos entre los objetivos de política.

El sexto informe analizó la crisis bancaria de 2023 que provocó la quiebra de Silicon Valley Bank y otros bancos regionales en Estados Unidos, así como de Credit Suisse, y sus implicaciones para la regulación financiera. Esta crisis bancaria constituyó el primer desafío significativo del marco de Basilea III, y el informe examinó posibles reformas para mejorar la estabilidad financiera. El informe se centró en tres temas principales: los cambios en la banca digital y la política monetaria que provocaron la crisis, y las reformas necesarias para el seguro de depósitos y el prestamista de última instancia; las deficiencias en la regulación, la contabilidad y la supervisión que provocaron la quiebra de bancos considerados solventes; y la gestión de las quiebras bancarias y las posibles reformas a los procedimientos de resolución.

Este séptimo informe aborda la transformación que la inteligencia artificial (IA), y más recientemente la IA generativa, ha supuesto para las finanzas. Dado que las finanzas se ocupan del procesamiento de la información, su impacto ya se siente y promete ser muy relevante en la intermediación financiera, las finanzas corporativas y los mercados financieros. La IA ofrece el potencial de importantes mejoras en la eficiencia, pero también plantea inquietudes sobre las implicaciones para la privacidad y el bienestar. El informe se centra en tres aspectos principales: el uso de la IA en la intermediación financiera, la banca central y los desafíos políticos y regulatorios; las implicaciones de la abundancia de datos y el comercio algorítmico para los mercados financieros; y la transformación que la IA supone para las finanzas corporativas, la contratación y la gobernanza.

El informe se elaboró tras el Taller y Conferencia sobre «Inteligencia Artificial en Finanzas», celebrado en el campus de Barcelona del IESE Business School los días 20 y 21 de marzo de 2025. El programa de la conferencia, junto con los comentarios de los ponentes, se incluye en este informe, al igual que el discurso inaugural del gobernador del Banco de España, José Luis Escrivá. Xavier Vives reunió al equipo de autores.

La Iniciativa Bancaria ha contado con el gran apoyo del decano del IESE, Franz Heukamp, y del exdecano, Jordi Canals. El CEPR y el IESE agradecen profundamente a los autores y ponentes su esfuerzo en la preparación de este informe, así como a los asistentes a la conferencia sus perspicaces comentarios. También agradecemos a Carlota Monner su eficiente organización de la conferencia y su apoyo para el informe, y a Anil Shamdasani su dedicación y paciencia en la publicación del informe.

Las opiniones expresadas en el informe son exclusivas de sus autores y no representan las del CEPR, que no asume ninguna postura institucional sobre política económica, ni las de sus respectivas organizaciones. El CEPR y el IESE se complacen en ofrecer una plataforma para el intercambio de opiniones sobre este tema.

Tessa Ogden
Director Ejecutivo, CEPR
Mayo de 2025

Xavier Vives
Director de la Iniciativa Bancaria del IESE

Resumen ejecutivo

La inteligencia artificial (IA), y en particular la IA generativa (GenAI), está transformando los sistemas financieros con una velocidad y un alcance que rivalizan con revoluciones tecnológicas anteriores como la electricidad e internet. La IA transforma la forma en que se genera, transmite y consume la información. A diferencia de tecnologías anteriores, la IA se distingue por su capacidad para procesar información de forma autónoma, interactuar mediante lenguaje natural y adaptar su toma de decisiones mediante el aprendizaje. En el sector financiero, basado fundamentalmente en la producción y el uso de información, estas capacidades son especialmente disruptivas. Las tecnologías de IA ya no son auxiliares; se están convirtiendo en el núcleo de la intermediación financiera, la gestión de activos, los sistemas de pago y la supervisión regulatoria. Los bancos están comenzando a implementar GenAI en diversas funciones, y la mayoría prevé que su uso se intensificará. Por lo tanto, las preguntas clave que motivan este informe no son si la IA alterará los sistemas financieros, sino cómo, en qué direcciones y con qué implicaciones para la estabilidad financiera, la competencia y el diseño de políticas.

La incorporación de la IA a las finanzas está redefiniendo roles, estructuras de información y dinámicas institucionales. Con la IA, las decisiones financieras que antes dependían del criterio humano, como las evaluaciones de solvencia, la ejecución de órdenes e incluso los análisis de supervisión, se configuran o toman cada vez más mediante algoritmos que aprenden y se actualizan continuamente con base en datos de alta dimensión. Este cambio no se limita a la velocidad o la automatización, sino a la transformación cualitativa de la toma de decisiones, la alineación de incentivos y los canales de transmisión de riesgos dentro del sistema financiero. También crea nuevas formas de dependencia —de software, infraestructura de datos y proveedores de servicios externos— que están transformando la arquitectura de las instituciones y los mercados financieros.

Fundamentalmente, las ganancias prometidas por la IA (mayor eficiencia, acceso más amplio, mejores pronósticos) no se distribuyen equitativamente y pueden conllevar nuevas fragilidades. La opacidad de los modelos de IA plantea desafíos para la rendición de cuentas y la gobernanza; la capacidad de las empresas dominantes para aprovechar la IA a gran escala amenaza la competencia y la inclusión; y la homogeneidad del diseño de los modelos puede amplificar los shocks sistémicos. Estas preocupaciones son particularmente graves en el sector financiero, donde la propagación de errores, la correlación conductual y la sensibilidad a las expectativas son características centrales de la dinámica del mercado. Al igual que con innovaciones anteriores, la IA puede resolver algunos problemas de larga data y, al mismo tiempo, generar nuevas externalidades y vulnerabilidades.

Basándose en investigaciones académicas recientes y evidencia empírica, el informe examina las transformaciones fundamentales inducidas por la IA y los desafíos políticos que plantea. Se centra en tres temas principales: (1) el uso de la IA en la intermediación financiera, la banca central y las políticas, y los desafíos regulatorios; (2) las implicaciones de la abundancia de datos.

y el comercio algorítmico para los mercados financieros; y (3) los efectos de la IA en las finanzas corporativas, la contratación y la gobernanza. En estos ámbitos, el informe enfatiza que, si bien la IA tiene el potencial de mejorar la eficiencia, la inclusión y la resiliencia, también plantea nuevas vulnerabilidades que exigen respuestas regulatorias adaptativas.

2

INTELIGENCIA ARTIFICIAL Y EL SECTOR FINANCIERO:

TRANSFORMACIONES, DESAFÍOS Y RESPUESTAS REGULADORAS

La aplicación de la IA en la intermediación financiera ha generado mejoras significativas en la selección, el seguimiento y la asignación de crédito. Los modelos de aprendizaje automático (ML) superan a la calificación crediticia tradicional, especialmente en entornos volátiles o en constante cambio. Destacan en el uso de grandes conjuntos de datos no estructurados (registros de transacciones, huellas digitales, señales de comportamiento), lo que permite una evaluación más matizada del riesgo del prestatario.

La evidencia empírica de las plataformas fintech en China y Estados Unidos demuestra que los modelos mejorados con IA no solo aceleran la aprobación de préstamos, sino que también amplían el acceso al crédito, especialmente entre los prestatarios con pocos recursos. Además, al reducir la dependencia de las garantías, la IA puede ayudar a canalizar capital hacia startups de alta productividad que, de otro modo, podrían verse limitadas.

Sin embargo, estas mejoras de eficiencia no se distribuyen uniformemente ni garantizan un aumento del bienestar. Las entidades crediticias de las fintech y las grandes tecnológicas suelen cobrar tipos de interés más altos que los bancos tradicionales, a pesar de sus mejores capacidades de selección. Esta prima puede reflejar un mayor riesgo, los costes tecnológicos o una escasa competencia en ciertos segmentos de prestatarios. En algunos casos, podría deberse al uso estratégico de la IA para discriminar precios basándose en la disposición a pagar inferida, trasladando así la renta informativa de los consumidores a las entidades crediticias. Esto implica que, si bien la IA mejora la precisión en la asignación de recursos, no necesariamente reduce los costes de intermediación financiera para los usuarios finales.

La creciente prevalencia de modelos de préstamo basados en IA también puede debilitar los canales tradicionales de transmisión monetaria. La disociación entre los préstamos y el valor de las garantías y la menor importancia de los préstamos relacionales reducen la sensibilidad de los flujos de crédito a las fluctuaciones de los tipos de interés. Esto tiene implicaciones tanto para la eficacia de las políticas macroeconómicas como para el riesgo sistémico. Además, la opacidad y la no linealidad de muchos modelos de IA dificultan la supervisión, sobre todo cuando su lógica subyacente no puede interpretarse ni auditarse fácilmente.

Los bancos centrales están implementando IA en funciones esenciales. Las herramientas de aprendizaje automático (ML) se utilizan para rastrear la actividad económica, detectar anomalías en los sistemas de pago y procesar grandes volúmenes de textos de supervisión. Estas herramientas ofrecen mayor velocidad y alcance, permitiendo a los supervisores identificar señales de alerta temprana y mejorar la supervisión macroprudencial. Sin embargo, también introducen un nuevo tipo de riesgo: la convergencia de modelos y la homogeneidad interpretativa. A medida que los bancos centrales y los participantes del mercado recurren cada vez más a sistemas de IA similares, aumenta la posibilidad de puntos ciegos comunes y de amplificación procíclica.

En resumen, la reconfiguración de la intermediación mediante IA mejora la capacidad predictiva y la eficiencia operativa, pero complica la política monetaria, altera la dinámica competitiva, con el potencial de un papel dominante de las grandes tecnológicas en la cadena de valor de la IA, e introduce nuevas fuentes de riesgo de modelo. El reto reside en fomentar la innovación impulsada por la IA, mitigando al mismo tiempo los riesgos relacionados con la inestabilidad financiera, las prácticas monopolísticas y las violaciones de la privacidad. Abordar estos problemas puede requerir un replanteamiento de los marcos de supervisión, posiblemente incluyendo protocolos de auditabilidad de modelos y prácticas más amplias de pruebas de estrés.

3

ABUNDANCIA DE DATOS, IA Y MERCADOS FINANCIEROS: IMPLICACIONES Y RIESGOS

Un segundo ámbito de transformación de la IA reside en los mercados de capitales, donde la abundancia de datos y la intermediación algorítmica han transformado los mecanismos de descubrimiento de precios, creación de mercado y gestión de activos. La proliferación de datos alternativos, que abarcan desde imágenes satelitales y flujos de tarjetas de crédito hasta redes sociales y geolocalización, ha creado nuevas fuentes de información más allá de la información financiera tradicional. Los modelos de IA, entrenados con estos conjuntos de datos de alta dimensión, extraen señales predictivas que antes eran inaccesibles o extremadamente costosas de obtener. El coste marginal de generar información financiera procesable se ha reducido drásticamente, desplazando la ventaja informativa del acceso a las capacidades de procesamiento.

Esta transformación ha generado mejoras de eficiencia. Los diferenciales entre oferta y demanda se han reducido, la provisión de liquidez se ha automatizado más y la precisión de las previsiones de beneficios, eventos crediticios y volatilidad ha mejorado. Sin embargo, estos beneficios conllevan nuevos riesgos sistémicos. En primer lugar, las estrategias de trading algorítmico suelen converger hacia patrones similares cuando se entrenan con datos superpuestos, lo que aumenta el riesgo de comportamiento sincronizado y caídas repentinas. Los agentes de aprendizaje por refuerzo, que optimizan mediante ensayo y error, pueden desarrollar estrategias inestables o explotadoras en equilibrio.

En segundo lugar, la IA puede intensificar las asimetrías informativas entre los participantes del mercado. Si bien la información divulgada es pública, solo quienes cuentan con suficientes recursos computacionales y modelos sofisticados pueden procesarla eficazmente. Estudios empíricos muestran que los analistas de instituciones equipadas con IA superan significativamente a sus pares cuando se dispone de datos alternativos. Como resultado, la IA puede reforzar el poder de mercado y ampliar la participación huecos.

En tercer lugar, la IA facilita nuevas formas de colusión tácita y opacidad estratégica. Los algoritmos de fijación de precios pueden aprender a coordinarse sin comunicación explícita, lo que reduce la presión competitiva y aumenta los márgenes. La línea entre la fijación legítima de precios dinámicos y la colusión algorítmica se difumina, especialmente en mercados donde unas pocas plataformas dominantes establecen condiciones para miles de usuarios. Además, dado que muchos modelos de IA no son interpretables, su comportamiento puede eludir tanto el escrutinio del mercado como la detección regulatoria hasta después de que se haya producido el daño.

Finalmente, la carrera armamentística por la velocidad y la extracción de señales ha desviado capital y talento hacia una competencia de suma cero. El retorno social de reducir microsegundos los tiempos de ejecución o explotar anomalías efímeras en los datos es limitado; sin embargo, las empresas invierten fuertemente en estas capacidades porque los retornos privados son altos. Esta discrepancia entre los incentivos privados y el valor social plantea interrogantes sobre la eficiencia general de la asignación de recursos de la IA en los mercados financieros.

Las posibles respuestas regulatorias podrían incluir la introducción de interruptores automáticos que tengan en cuenta la latencia, la exigencia del acceso público a los datos de precios de referencia y la exigencia de la divulgación de las arquitecturas de modelos en ciertos contextos comerciales. Su diseño y eficacia dependerán de una experimentación rigurosa, el aprendizaje interjurisdiccional y el diálogo continuo entre los participantes del mercado y los reguladores.

En conjunto, estos avances apuntan a un sistema financiero en el que la información es más abundante pero también está distribuida de manera más desigual; en el que las transacciones son más rápidas pero también más frágiles; y en el que la transparencia es técnicamente factible pero prácticamente difícil de conseguir. Una respuesta política debe ir más allá de la divulgación y abordar el acceso a la infraestructura, la auditabilidad de los modelos y la alineación de los incentivos, si bien reconociendo que estas intervenciones conllevan complejidades de diseño y compensaciones que aún deben comprenderse plenamente.

FINANZAS CORPORATIVAS Y GOBIERNO CON IA: ANTIGUO Y NUEVO

Un tercer ámbito de la transformación de la IA se relaciona con las finanzas corporativas, la contratación y la gobernanza. La IA altera elementos fundamentales del control corporativo, redefiniendo la dinámica de las agencias, las asimetrías de información y la naturaleza de la contratación financiera. Si bien los sistemas de IA no buscan su propio interés en el sentido humano, introducen un tipo específico de problema de agencia: la desalineación de la optimización. Los agentes autónomos entrenados mediante aprendizaje por refuerzo pueden satisfacer objetivos específicos de maneras que socavan objetivos regulatorios o éticos más amplios. Una IA encargada de minimizar los impagos de préstamos, por ejemplo, podría incurrir en comportamientos discriminatorios o explotar proxies de datos que los reguladores consideran inaceptables. Dado que estos sistemas son adaptativos y opacos, detectar y corregir dichos comportamientos después de su implementación es costoso e incierto.

Esto plantea profundas cuestiones de rendición de cuentas. El gobierno corporativo tradicional se basa en la atribución de intenciones y la asignación de responsabilidades. Sin embargo, cuando las decisiones las toman sistemas que aprenden y evolucionan independientemente de instrucciones directas, los mecanismos legales e institucionales de cumplimiento comienzan a debilitarse. La dificultad de auditar modelos complejos de aprendizaje automático (ML) agrava este desafío. Sin requisitos de interpretabilidad sólidos ni mecanismos de trazabilidad integrados, las instituciones financieras corren el riesgo de implementar sistemas cuyo comportamiento no pueden explicar por completo, y mucho menos controlar.

La asimetría de la información también se está reconfigurando. Anteriormente, quienes tenían información privilegiada contaban con ventajas informativas derivadas del acceso privilegiado a registros y pronósticos internos. Hoy, la IA permite a los externos inferir las condiciones de la empresa a partir de flujos de datos externos, lo que reduce dicha asimetría. Los inversores sofisticados utilizan datos alternativos y herramientas de procesamiento del lenguaje natural para analizar las cadenas de suministro, las opiniones y las señales de comportamiento, y pueden anticipar la divulgación corporativa. En respuesta, las empresas han comenzado a adaptar sus comunicaciones al consumo algorítmico, transformando aún más el entorno de la información. Por ejemplo, la Regulación de Divulgación Justa de EE. UU. y leyes similares podrían necesitar evolucionar para garantizar no solo la igualdad de acceso, sino también la igualdad de usabilidad de la información pública.

En el ámbito de la contratación, la IA está acelerando la adopción de contratos inteligentes, acuerdos automatizados que se ejecutan automáticamente con base en la entrada de datos en tiempo real. Estos contratos reducen los costos de ejecución y limitan el margen de renegociación oportunista. Sin embargo, también introducen rigidez. Las llamadas de margen automatizadas o los eventos desencadenantes pueden propagarse en cascada por los mercados, especialmente cuando varios actores dependen de modelos y umbrales similares. La falta de discreción o contexto puede convertir a los contratos inteligentes en una fuente de riesgo sistémico en tiempos de tensión.

La solución podría residir en modelos de gobernanza híbridos. Los contratos podrían incorporar flexibilidad ex ante, mediante cláusulas de renegociación macrosensibles, opciones de anulación de la intervención humana y registros de auditoría claros. Los sistemas de IA podrían estar sujetos a principios de rendición de cuentas análogos a los aplicados a los agentes humanos: comprensibilidad, trazabilidad y autonomía limitada. Los marcos legales podrían evolucionar gradualmente desde la intención subjetiva hacia la responsabilidad basada en resultados, y desde formas contractuales fijas hacia protocolos de gobernanza más adaptables.

CONCLUSIÓN

La integración de la IA en los sistemas financieros constituye una transformación estructural, no un ajuste marginal. Los beneficios —en términos de eficiencia, precisión e inclusión— son sustanciales, pero también lo son los riesgos para la estabilidad, la equidad y la gobernanza. Si los responsables políticos están a la altura del reto, la IA puede aprovecharse para mejorar el rendimiento y la inclusión del sistema financiero. De lo contrario, estas mismas tecnologías podrían socavar los cimientos mismos de la confianza financiera.

Si bien los límites del impacto a largo plazo de la IA siguen siendo inciertos, su trayectoria a corto plazo ya está transformando las instituciones, los mercados y las normas regulatorias. Para guiar esta transformación, será necesaria una mayor experimentación regulatoria y coordinación institucional. Estos esfuerzos no solo deben apuntar a contener el riesgo, sino también a liberar el potencial inclusivo de la IA, garantizando que sus beneficios se distribuyan ampliamente y que sus mecanismos sean legibles y controvertidos.

Esto requerirá desarrollar capacidad técnica dentro de los organismos reguladores, revisar las definiciones legales de rendición de cuentas y fomentar mecanismos de coordinación internacional.

Los flujos transfronterizos de datos, el acceso a modelos fundamentales y la interoperabilidad de plataformas serán cada vez más importantes para la diplomacia financiera. De igual manera, podría ser necesario explorar nuevos marcos para evaluar la importancia sistémica de la IA, similares a los desarrollados para los bancos globales de importancia sistémica. Estos deberían ir acompañados de una planificación basada en escenarios para anticipar las amenazas emergentes y evaluar la resiliencia institucional ante las disrupciones generadas por la IA.

El éxito de la gobernanza financiera dependerá en parte de la eficacia con la que los reguladores equilibren la innovación y el control. Una regulación excesiva puede frenar el uso productivo de la IA, mientras que una regulación insuficiente corre el riesgo de crear puntos ciegos sistémicos. Este equilibrio requiere mecanismos adaptativos para revisar supuestos, actualizar las normas e interactuar con un ecosistema más amplio de partes interesadas.

Finalmente, el futuro de la IA en las finanzas estará determinado por fuerzas geopolíticas más amplias. La fragmentación de los regímenes de gobernanza digital en Estados Unidos, la Unión Europea y China podría obstaculizar el establecimiento de estándares globales, mientras que la concentración de la infraestructura informática y la experiencia en modelos en unas pocas empresas y jurisdicciones plantea inquietudes sobre la soberanía económica y la resiliencia. Los responsables políticos deben anticipar escenarios en los que la IA se convierta en un foco de disputa estratégica.

El impacto transformador de la inteligencia artificial en el sector financiero y los bancos centrales¹

7

José Luis Escrivá Belmonte²

Gobernador del Banco de España

La inteligencia artificial (IA) se ha convertido rápidamente en una de las tecnologías más impactantes y transformadoras de nuestra era. Si bien las revoluciones tecnológicas anteriores trajeron cambios significativos a la industria manufacturera o pesada, la IA destaca por su capacidad para transformar el sector servicios. Anteriormente, los servicios se habían mostrado más aislados en cuanto a aumentos de productividad, y lo que realmente marca la diferencia con la IA es su potencial para generar considerables aumentos de productividad en este sector, siendo transformadora para toda la economía, pero principalmente para el mundo occidental, cada vez más especializado en servicios.

Históricamente, los servicios financieros han sido de los primeros en adoptar la innovación tecnológica. Ahora, la IA ofrece nuevas vías para aumentar la eficiencia, mejorar la toma de decisiones y mejorar la productividad.

En este contexto, los bancos centrales prestan gran atención a este potencial disruptivo. La IA no es un simple programa informático, sino una tecnología de propósito general que puede permear todas las funciones de un banco central. Para los bancos centrales, la IA también tiene un efecto transformador, permitiéndoles abordar un número creciente de cuestiones complejas y novedosas, desde la monitorización del riesgo sistémico hasta la orientación de la política monetaria. El reto reside en integrar la IA de forma que se maximice su potencial, gestionando al mismo tiempo los riesgos asociados a esta potente tecnología. En este artículo, exploro el enfoque del Banco de España para la adopción de la IA, las oportunidades y los retos que presenta, y los elementos estratégicos fundamentales para su implementación.

PERSPECTIVAS DE LOS BANCOS CENTRALES SOBRE LA ADOPCIÓN DE LA IA

En el contexto de la función multifacética de un banco central, la IA afecta tanto a funciones centradas en la gestión de riesgos (estabilidad financiera y supervisión), como a aquellas con mayores oportunidades de innovación (pagos, operaciones financieras y política monetaria). En esta sección, exploro cómo el Banco de España considera el impacto de la IA en estas dimensiones.

¹ Esta es una versión editada de la ponencia pronunciada en la VII Conferencia de Inteligencia Artificial del IESE Finanzas^{*} el 21 de marzo de 2025.

² Las opiniones expresadas aquí son las del autor y no representan necesariamente las del Banco de España, el Banco Central Europeo o el Eurosistema.

En cuanto a la estabilidad financiera, la integración de la IA en el sector financiero, como cualquier gran transformación, plantea ciertos desafíos. Los bancos centrales deben mantenerse alertas en la gestión de estos riesgos, garantizando que los sistemas de IA no generen vulnerabilidades que puedan amenazar la estabilidad financiera. Desde una perspectiva macroprudencial, preservar la estabilidad financiera a nivel europeo y mundial requiere anticipar estos posibles impactos negativos.

El riesgo transicional al adoptar una nueva tecnología debe examinarse cuidadosamente desde una perspectiva de estabilidad financiera y por su potencial para crear problemas sistémicos.

Se debe monitorear la inversión temprana en tecnologías inferiores, así como la inversión tardía, que conlleva pérdida de competitividad. Además, una de las preocupaciones más apremiantes es la posible mayor interdependencia de las instituciones financieras y la concentración de proveedores de tecnología de IA. Si un pequeño número de empresas domina la infraestructura de IA, el fracaso de una o más podría tener efectos en cascada sobre la estabilidad financiera global.

Los desafíos incluyen abordar cuestiones como la adopción de modelos financieros de alto riesgo, donde la transparencia y la rendición de cuentas son cruciales para evitar resultados negativos como la discriminación o la toma de decisiones injusta.

EL IMPACTO TRANSFORMADOR DE LA IA EN LA BANCA CENTRAL



Otro ámbito donde se está examinando detenidamente el impacto de la IA es el de la supervisión microprudencial y de conducta. El uso de modelos de IA en áreas como la calificación crediticia y la toma de decisiones crediticias puede generar preocupaciones éticas, en particular en lo que respecta a la equidad y la protección de los derechos individuales. Al aplicarse a personas individuales, estos se identifican como sistemas de alto riesgo según la Ley de IA y deberían estar bajo la supervisión de las autoridades de vigilancia del mercado. Los supervisores financieros, encargados de desempeñar esa función, han destacado la importancia de supervisar de cerca estos sistemas para proteger a las personas de posibles resultados injustos. En la práctica, se necesita una supervisión de conducta sólida para prevenir consecuencias no deseadas, como la discriminación en la concesión de productos financieros.

En este contexto, la IA representa tanto una oportunidad como un desafío. Si bien puede mejorar la eficiencia operativa, los modelos utilizados en áreas como la calificación crediticia y la suscripción de seguros deben analizarse cuidadosamente para garantizar que no perjudiquen inadvertidamente a los consumidores ni socaven la confianza en el sistema financiero.

Más allá de la supervisión, los pagos y las operaciones financieras, normalmente en el centro de la innovación tecnológica, están en el lado de las oportunidades de esta transformación.

La IA también está preparada para influir en la política monetaria. Los bancos centrales deben comprender el impacto potencial en la transmisión de la política monetaria. Además, el potencial de la IA para impulsar mejoras de productividad en toda la economía también podría influir en el entorno macroeconómico general, alterando la tasa de crecimiento potencial de las economías y la eficacia de la política monetaria.

La IA también puede mejorar nuestras capacidades analíticas y la capacidad de procesar información granular. Los modelos de pronóstico tradicionales se basan en supuestos lineales, mientras que las tendencias económicas del mundo real suelen seguir patrones complejos y no lineales. La IA destaca en la identificación de estas sutilezas, lo que permite a los responsables políticos captar señales potencialmente más precisas relacionadas con la inflación, el empleo y el dinamismo económico general.

Si bien cuantificar el impacto total de la IA en estas áreas es un desafío, está claro que la tecnología desempeñará un papel central en la configuración de los futuros modelos económicos y las estrategias de los bancos centrales.


FACTORES QUE FACILITAN EL AVANZAR CON LA IA

Si bien el potencial de la IA es innegable, el salto de los programas piloto y los proyectos de prueba de concepto a la adopción a gran escala depende de múltiples factores facilitadores.

En el Banco de España, hemos identificado siete elementos clave para garantizar que la adopción de la IA sea exitosa y sostenible. Una infraestructura computacional robusta, marcos fiables para el intercambio de datos, talento cualificado y una normativa clara son esenciales para fomentar la innovación responsable impulsada por la IA. Igualmente importante es el énfasis en la colaboración, tanto dentro del sector financiero como a nivel institucional, nacional y europeo.

ELEMENTOS CLAVE PARA AMPLIAR EL USO DE IA

ELEMENTOS CLAVE PARA AVANZAR



Un primer aspecto crítico para la adopción de la IA es el acceso a una infraestructura computacional de vanguardia. El entrenamiento de modelos de IA grandes y complejos para aplicaciones financieras requiere un uso intensivo de recursos, lo que impulsa la necesidad de computación de alto rendimiento. Para satisfacer esta demanda, la Comisión Europea ha puesto en marcha el proyecto AI Factories, que establece centros de vanguardia en todo el continente. Se han aprobado siete emplazamientos en España (el Centro de Supercomputación de Barcelona), Italia (IT4LIA), Alemania (HammerHAI), Finlandia (LUMI AI Factory), Luxemburgo (L-AI Factory), Grecia (Pharos) y Suecia (MIMER).

Cada fábrica de IA se especializa en ciertos sectores verticales, y la de Barcelona se centrará en las finanzas. Esta configuración busca evolucionar de la computación orientada a la investigación a instalaciones capaces de proporcionar entrenamiento y experimentación con modelos a escala industrial, tanto para el sector privado como para el público. La siguiente fase, a menudo denominada «gigafábricas» de IA, abordará la inferencia a escala, optimizando los centros de datos para ejecutar cargas de trabajo de IA avanzadas en entornos reales.

Además de estas iniciativas a gran escala, los avances en hardware también son fundamentales.

La creciente dependencia de las unidades de procesamiento gráfico (GPU) y las unidades de procesamiento neuronal (NPU) para ejecutar modelos de IA es fundamental para la evolución de las capacidades computacionales.

Las GPU destacan en tareas de computación paralela esenciales para el entrenamiento de sistemas modernos de aprendizaje automático, mientras que las NPU se especializan en computación de redes neuronales profundas. A medida que estas tecnologías de hardware evolucionen, los bancos centrales estarán mejor posicionados para implementar modelos avanzados de IA, gestionando al mismo tiempo el consumo energético y los costes de infraestructura.

Más allá del hardware, la IA también se basa en modelos y algoritmos. Los grandes modelos de lenguaje (LLM) han cobrado protagonismo, pero entrenarlos puede ser costoso y requerir un uso intensivo de datos, por lo que las técnicas de compresión de modelos resultan invaluable.

Al reducir el tamaño y la complejidad de los modelos de IA, sin comprometer significativamente el rendimiento, las instituciones pueden implementar LLM de manera más eficiente y a un menor costo.

Las técnicas pueden reducir las barreras de adopción para instituciones más pequeñas, reduciendo la energía y el tiempo necesarios para la capacitación. El reto también reside en pasar de modelos lingüísticos con un mayor porcentaje de lenguas latinas a modelos especializados que puedan depender y funcionar en una infraestructura menos costosa.

El tercer elemento clave es la computación en la nube, cada vez más esencial para la implementación de la IA por parte de las instituciones financieras. La ciberseguridad contribuirá a garantizar la ciberresiliencia, la continuidad operativa y la privacidad de los datos, pero la usabilidad y la capacidad de ampliar las capacidades analíticas también son cruciales. Los bancos centrales deben equilibrar la flexibilidad y la escalabilidad de las soluciones de nube pública con las exigencias de privacidad y seguridad de los datos financieros sensibles, encontrando una solución práctica en los modelos de nube híbrida.

Los datos, como cuarto elemento, son el motor de cualquier sistema de IA. Una función de producción tradicional se compone de capital humano, capital físico e innovación. Ahora, la información se ha convertido en un factor más de producción, un ingrediente clave en la producción de bienes.

Un factor facilitador de la IA es el cambio de silos de datos "cerrados" a entornos de datos más abiertos o al menos compatibles.

Cumplir con los estándares de confidencialidad y privacidad es fundamental, pero un acceso más amplio a los datos ayuda a las instituciones a construir modelos más completos y precisos. El Banco de España ha comenzado a compartir un número creciente de conjuntos de datos para impulsar la innovación en el ámbito académico y otros organismos de investigación, convencido de que la colaboración informada beneficia a la sociedad en su conjunto. En el futuro, la combinación de diferentes conjuntos de datos e información, preservando la confidencialidad y el anonimato, permitirá aprovechar los beneficios de la IA.

Incluso con una infraestructura de vanguardia, las iniciativas de IA pueden estancarse sin capital humano cualificado. Este es el siguiente elemento. Nuestra encuesta a empresas españolas reveló que el principal obstáculo para el desarrollo y la adopción de la IA es la falta de personal cualificado. La escasez de talento también obstaculizará la capacidad de los bancos centrales para alcanzar sus objetivos en materia de IA.

Contratar y retener científicos de datos, ingenieros de IA y expertos en la materia es un desafío reconocido, sobre todo porque el sector tecnológico privado suele ofrecer remuneraciones más competitivas. Los bancos centrales deberían potenciar la labor del sector público, impulsada por una misión, centrándose en la estabilidad económica y el beneficio social, lo cual puede resultar atractivo para muchos profesionales. Además del valor del servicio público, los bancos centrales también pueden ofrecer proyectos a largo plazo y la capacidad de aumentar la colaboración y el intercambio de recursos entre ellos.

Al mismo tiempo, los bancos centrales deben dedicarse a la capacitación y actualización de sus empleados y promover un cambio cultural en todo el personal, además de capacitar a las personas en el uso responsable y ético de la IA.

Como elemento adicional, unos marcos regulatorios claros son indispensables para la expansión segura de la IA. En ausencia de directrices bien definidas, las empresas pueden dudar en integrar la IA a gran escala, por temor a repercusiones legales o reputacionales. La regulación europea de la IA ha sido criticada, pero en ausencia de regulación y en medio de la incertidumbre...

Debido a los posibles problemas de reputación asociados con el uso de la IA, las empresas podrían mostrarse reacias a pasar de las pruebas de concepto y los casos prácticos a la adopción y el uso regular de la IA. En este sentido, la ausencia de una regulación clara o de claridad en cuestiones como los derechos de autor podría disuadir el uso de la IA. La Ley de IA en Europa podría disipar estas incertidumbres.

12

La propuesta de regulación de IA de la Unión Europea busca un enfoque equilibrado entre el fomento de la innovación y la protección de los derechos individuales, categorizando las aplicaciones de IA por nivel de riesgo e imponiendo requisitos más estrictos a los modelos de alto riesgo (como los modelos para la concesión de crédito a particulares). Al apoyar el desarrollo de una normativa integral, el Banco de España pretende crear un entorno que permita el desarrollo de la IA, mitigando al mismo tiempo los riesgos potenciales.

Finalmente, la adopción exitosa de la IA será imposible sin la cooperación entre diversos actores en todos los ámbitos. Esto incluye la coordinación con supervisores como la Agencia Española de Inteligencia Artificial (AESIA) y entre bancos centrales para alinearse con los estándares, y con el sector financiero, ofreciendo entornos controlados («sandboxes») para probar aplicaciones de IA y permitir que bancos y fintechs refinen sus innovaciones, garantizando al mismo tiempo el cumplimiento normativo. Finalmente, la colaboración con universidades, empresas tecnológicas y centros de supercomputación como el Barcelona Supercomputing Center impulsará la investigación y la escalabilidad. Estas colaboraciones proporcionarán tanto la experiencia como los recursos computacionales de alta gama necesarios para despliegues de IA a gran escala.

El centro de experimentación y desarrollo que el Banco de España proyecta construir en Barcelona refleja perfectamente esta filosofía, ofreciendo un espacio donde el sector financiero puede probar nuevas herramientas de IA en condiciones reales y al mismo tiempo beneficiarse de la orientación regulatoria y de recursos informáticos avanzados.

CONCLUSIÓN: EL FUTURO DE LA IA EN LA BANCA CENTRAL

La integración de la IA en la banca central aún se encuentra en sus primeras etapas, pero su potencial para transformar el sistema financiero es innegable. A medida que la IA continúa evolucionando, los bancos centrales deben mantener su agilidad y colaborar estrechamente con otras instituciones financieras, reguladores y socios internacionales para garantizar que las tecnologías de IA se utilicen de forma responsable. En los próximos años, la IA desempeñará un papel transformador en el funcionamiento de los bancos centrales, influyendo en todos los ámbitos, desde la política monetaria hasta la estabilidad financiera. Para el Banco de España, el camino acaba de comenzar y las oportunidades que se avecinan son inmensas.

CAPÍTULO 1

Introducción

13

La inteligencia artificial (IA), en particular la IA generativa (GenAI) y los grandes modelos de lenguaje (LLM), está transformando la intermediación financiera, la gestión de activos, los pagos y los seguros. Desde la década de 2010, el aprendizaje automático (ML) ha tenido un impacto significativo en diversas áreas, como el análisis de riesgo crediticio, el trading algorítmico y el cumplimiento normativo contra el blanqueo de capitales (AML). Hoy en día, las instituciones financieras utilizan cada vez más la IA para optimizar las operaciones administrativas, mejorar la atención al cliente mediante chatbots y optimizar la gestión de riesgos mediante análisis predictivos.

La IA se centra principalmente en predecir resultados, identificar patrones en los datos (mediante aprendizaje automático) y ofrecer recomendaciones para la toma de decisiones y la acción.¹ La IA puede operar en tres niveles de autonomía creciente: como un «oráculo», que proporciona perspectivas y recomendaciones (es decir, información),² dejando las decisiones en manos de los humanos; como un «agente», que realiza tareas dentro de límites predefinidos bajo supervisión humana (el «copiloto», que asiste en las tareas diarias, es una función que combina oráculo y agente); y como un «humano» o «soberano», que toma decisiones independientes en tiempo real. Independientemente de estos niveles de autonomía, los LLM ya han revolucionado la interacción persona-computadora, pasando de las interfaces de código abierto a texto y voz naturales. Además, la IA ha impactado a todos los sectores industriales, aunque en distintos grados. La banca y las finanzas están particularmente bien posicionadas para lograr importantes mejoras de eficiencia gracias a su dependencia del procesamiento de la información.³

La fusión de las finanzas y la tecnología se ha convertido en una fuerza transformadora que genera tanto desafíos como oportunidades para las prácticas e investigaciones financieras.⁴ La adopción de tecnologías financieras ha generado importantes disrupciones, desplazando puestos de trabajo en roles tradicionales y, al mismo tiempo, impulsando una sólida demanda de expertos capaces de integrar las finanzas y la tecnología. Esta evolución va más allá de la simple automatización y fomenta la «cointeligencia», una interacción colaborativa entre humanos y máquinas.⁵

1 La OCDE (2021) define la inteligencia artificial como "sistemas basados en máquinas [...] que [...] pueden hacer predicciones, recomendaciones o decisiones utilizando cantidades masivas de fuentes de datos alternativas y análisis de datos conocidos como big data", mientras que la Ley de IA de la UE define un sistema de IA como "un sistema basado en máquinas que está diseñado para operar con distintos niveles de autonomía y que puede exhibir adaptabilidad después de la implementación, y que, para objetivos explícitos o implícitos, infiere, a partir de la entrada que recibe, cómo generar resultados tales como predicciones, contenido, recomendaciones o decisiones que pueden influir en entornos físicos o virtuales".

2 Un "oráculo" en el contexto de las cadenas de bloques significa un puente de datos; aquí tiene un significado diferente (véase Bostrom, 2015).

3 Véase Acemoglu et al. (2022) y BIS (2024).

4 Véase el cuarto informe El Futuro de la Banca (Duffie et al., 2022).


5 Véase Jiang et al. (2025b).

La revolución del big data, impulsada por la abundancia de datos, los avances en la ciencia de datos (incluida la IA) y el aumento de la potencia computacional, está transformando la forma en que se genera la información. En particular, el aprendizaje automático (ML) permite realizar predicciones a partir de grandes conjuntos de datos y automatiza las decisiones basadas en estas predicciones.

La IA y el big data mejoran la eficiencia de la intermediación financiera (por ejemplo, pagos y concesión de crédito), mejoran la calidad de la información en los mercados financieros y la transparencia de los precios de los activos, además de promover la inclusión financiera. Sin embargo, esta transformación introduce riesgos relacionados con la estabilidad financiera, la integridad y la concentración del mercado, y la privacidad y la protección del consumidor, lo que plantea importantes desafíos para los reguladores.

La literatura académica sobre economía y finanzas relacionada con la IA y sus efectos está en rápido crecimiento. Al mismo tiempo, la IA se ha convertido en una herramienta poderosa para la investigación científica en diversos campos, como la biología, la química y la economía, incluyendo la economía financiera (por ejemplo, en la valoración de activos, la gestión de carteras, la gestión de riesgos y las finanzas corporativas). El número de artículos en revistas financieras y económicas que utilizan herramientas de IA ha aumentado considerablemente en la última década (véase la Figura 1). Este informe se basa en investigación académica y se centra en la aplicación de herramientas de IA en mercados, empresas e intermediarios.

FIGURA 1 NÚMERO DE ARTÍCULOS QUE UTILIZAN HERRAMIENTAS DE IA Y/O ESTUDIAN LOS EFECTOS DE LA IA PUBLICADO EN LAS PRINCIPALES REVISTAS DE ECONOMÍA (ARRIBA) Y FINANZAS (ABAJO), 2015-2024



Nota: Esta figura muestra el número de artículos que utilizan herramientas de IA o que estudian sus efectos, publicados en las principales revistas de economía (panel superior) y de finanzas (panel inferior). Los números en la parte superior de cada barra representan el total de artículos publicados en los respectivos grupos de revistas incluidos en el análisis. Consulte el Apéndice para obtener más información sobre la construcción de la figura.

En el resto de este capítulo introductorio, resumimos el análisis y las perspectivas políticas del informe. La sección 1.1 analiza las novedades y los avances en el uso de la IA en las finanzas. La Sección 1.2 resume la visión general del Capítulo 2, que examina las transformaciones y los desafíos que la IA plantea al sector financiero. La Sección 1.3 resume el Capítulo 3, que analiza las implicaciones de la abundancia de datos y las nuevas técnicas de negociación en los mercados financieros. La Sección 1.4 resume el Capítulo 4, que se centra en las implicaciones de la IA para las finanzas corporativas. La Sección 1.5 concluye destacando las principales implicaciones políticas.

1.1 CARACTERÍSTICAS Y USOS DE LA IA EN FINANZAS: QUÉ ES ANTIGUO Y QUÉ ES ¿NUEVO?


GenAI tiene tres características clave que la distinguen de otras tecnologías de propósito general.

La primera característica es la automaticidad. A diferencia de las generaciones anteriores de IA, los modelos GenAI pueden operar de forma independiente, realizando predicciones y tomando decisiones sin intervención humana.

El segundo es la velocidad de uso y adopción. Los LLM pueden procesar grandes cantidades de datos y tomar decisiones en fracciones de segundo, superando con creces las capacidades humanas. Además, la adopción de los LLM avanza a un ritmo sin precedentes, superando revoluciones tecnológicas anteriores, como las de la electricidad e internet (Figura 2A). Por ejemplo, ChatGPT alcanzó un millón de usuarios en menos de una semana.

La tercera característica es la ubicuidad. Casi la mitad de los hogares estadounidenses han utilizado herramientas GenAI durante el último año. Como reflejo de esta rápida adopción por parte de los usuarios, empresas de todos los sectores están integrando rápidamente GenAI en sus operaciones diarias (Figura 2B).

FIGURA 2 LA ADOPCIÓN DE LA IA



Notas: 1 La adopción de ChatGPT se calcula mediante la relación entre el número máximo de visitas a sitios web a nivel mundial durante el período de noviembre de 2022 a abril de 2023 y la población mundial con conexión a internet. Para más información sobre computadoras, consulte la Oficina del Censo de EE. UU.; para energía eléctrica, internet y redes sociales, consulte Our World in Data; para teléfonos inteligentes, consulte Statista. 2 Basado en una encuesta global de abril de 2023 con 1684 participantes.

INTELIGENCIA

	INTELIGENCIA				Seguro		Gestión		Pagos	
	Oportunidades	Desafíos	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto
Tradicional analítica	Oportunidades	Desafíos	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto
	Desafíos	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto
	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto
	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto
aprendizaje y	Oportunidades	Desafíos	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto
	Desafíos	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto
	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto
	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto
Generativo AI	Oportunidades	Desafíos	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto
	Desafíos	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto
	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto
	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto	Impacto

INTELIGENCIA

Dada su dependencia del procesamiento de información y de las tareas cognitivamente exigentes, el sector financiero se encuentra entre los más expuestos a la IA. Cada ola de tecnología de procesamiento de información ha dejado una huella significativa en el sistema financiero, abriendo nuevas vías para la eficiencia y la innovación. Como exploraremos, la integración de GenAI en las finanzas está transformando el funcionamiento de los mercados, la gestión del riesgo por parte de las instituciones y la interacción de los consumidores con los servicios financieros.

Si bien el entusiasmo en torno a los LLM es reciente, el uso de la IA en el sector financiero no es nuevo. La Tabla 1 describe las oportunidades y los desafíos que la evolución de la IA, desde la analítica tradicional y progresando a través del aprendizaje automático hasta la GenAI, ha generado para el sector financiero. La tabla se centra en las cuatro funciones financieras clave: intermediación financiera, seguros, gestión de activos y pagos.

La analítica tradicional, caracterizada por sistemas expertos basados en reglas, se ha utilizado ampliamente en el sistema financiero durante décadas. Ha respaldado la evaluación de riesgos, el análisis crediticio basado en reglas, la optimización de carteras y la detección de fraudes. Desde la década de 2010, los modelos de aprendizaje automático (ML) también han incursionado en el análisis de riesgos crediticios y de seguros, las operaciones de alta frecuencia (HFT), la lucha contra el blanqueo de capitales (AML) y la financiación del terrorismo.

GenAI, la última evolución, ya está siendo utilizada por instituciones financieras para optimizar el procesamiento back-end, el robo-advising, la atención al cliente y el cumplimiento normativo. Automatiza tareas que antes se consideraban exclusivamente humanas, como asesorar a los clientes y persuadirlos para que adquieran productos y servicios financieros. Según el Instituto de Finanzas Internacionales (2025), el 89 % de los bancos ya utiliza GenAI y el 94 % prevé una mayor dependencia de soluciones de IA de terceros.

1.2 INTELIGENCIA ARTIFICIAL Y EL SECTOR FINANCIERO:

TRANSFORMACIONES, DESAFÍOS Y RESPUESTAS REGULADORAS

El capítulo 2 examina las transformaciones que la IA aporta a las finanzas, destacando tanto las oportunidades como los desafíos. Explora cómo la IA, y en particular la GenAI, está transformando radicalmente la intermediación financiera, la gestión de riesgos y la supervisión regulatoria. El análisis se centra en el papel de la IA en la eficiencia económica, el crédito, la regulación y la banca central.

1.2.1 IA en finanzas: Nuevas oportunidades

Evaluación y análisis de riesgo crediticio

La adopción de IA en los mercados de crédito ha introducido cambios fundamentales en la evaluación del riesgo crediticio, la fijación de precios y la dinámica institucional.

1. Los modelos de calificación crediticia basados en IA mejoran significativamente la precisión de la predicción de riesgos al aprovechar fuentes de datos no estructurados a gran escala, más allá de las métricas financieras tradicionales. Las entidades financieras tecnológicas integran datos alternativos, como huellas digitales y registros de transacciones, en sus modelos de calificación crediticia, lo que permite una mayor granularidad.

Evaluación del prestatario. Sin embargo, si bien estos modelos permiten una tramitación más rápida de préstamos —reduciendo los tiempos de aprobación de hipotecas en un 20%, según algunos estudios—, no necesariamente reducen los costos de endeudamiento. La evidencia empírica de Estados Unidos muestra que algunas entidades financieras fintech han cobrado una prima sobre los bancos tradicionales, lo que sugiere que las mejoras de eficiencia de la IA no se trasladan completamente a los prestatarios. Esto puede deberse a altos costos de TI o de financiamiento, factores de riesgo, beneficios de conveniencia o competencia limitada en segmentos específicos del mercado.⁶

2. Los modelos ML superan a los métodos convencionales de calificación crediticia basados en logit, en particular en la adaptación a shocks regulatorios y condiciones económicas cambiantes.

La evidencia de China muestra que los modelos de crédito fintech mantuvieron su capacidad predictiva incluso cuando los modelos tradicionales se deterioraron tras los cambios regulatorios del sector financiero. Esta adaptabilidad subraya la capacidad de los modelos no lineales para captar la evolución de la dinámica del riesgo y su robustez en entornos más volátiles.

3. Las grandes tecnológicas presentan tasas de impago más bajas que los bancos tradicionales, no solo debido a una mejor evaluación de riesgos, sino también a los efectos del ecosistema. Las empresas que operan en plataformas digitales se enfrentan a mayores costes de cambio y a mecanismos indirectos de cumplimiento —como deducciones por reembolso basadas en transacciones o exclusión del ecosistema— que disuaden el impago estratégico. Sin embargo, a pesar del menor riesgo crediticio ex post, las grandes tecnológicas pueden cobrar tipos de interés más altos, lo que refleja su acceso limitado a depósitos minoristas, un mayor riesgo ex ante para el prestatario y los costes fijos asociados a la infraestructura crediticia impulsada por IA. Este doble impacto de la IA en los préstamos —mejora la evaluación de riesgos e introduce nuevas fricciones en la fijación de precios— configura la estructura del mercado y el comportamiento del prestatario.

Monitoreo y garantías

Los modelos de préstamo basados en IA y en formas alternativas de datos permiten resolver problemas de información asimétrica sin usar garantías. La evidencia empírica de China sugiere que el crédito de las grandes tecnológicas suele carecer de garantías y estar en gran medida desvinculado de las condiciones macroeconómicas y del mercado inmobiliario, respondiendo, en cambio, a cambios en las condiciones específicas de cada empresa. Este cambio debilita el canal tradicional de garantías para la transmisión monetaria, al tiempo que permite a las pequeñas empresas, en particular a las del sector informal, generar historiales financieros verificables mediante pagos digitales, lo que aumenta su acceso al crédito bancario.

Sin embargo, el crédito impulsado por IA también presenta nuevos riesgos. El éxito de los préstamos de las fintech y las grandes tecnológicas depende de la calidad de los datos y la precisión predictiva, y en algunos casos, los prestamistas basados en IA han sustituido a los bancos tradicionales en la atención a prestatarios de mayor riesgo. Al mismo tiempo, el uso del aprendizaje automático en la calificación crediticia está disminuyendo el papel de las relaciones bancarias a largo plazo, lo que podría reducir los beneficios de estabilidad financiera asociados.

⁶ Véase Vives y Ye (2025b).

Con préstamos relacionales. En conjunto, la asignación de crédito impulsada por IA fomenta el crecimiento de las pequeñas y medianas empresas (PYME) y una mayor inclusión financiera. La evidencia de China indica un aumento de la actividad empresarial y la resiliencia a las crisis económicas entre los prestatarios que reciben crédito de las grandes tecnológicas. Además, la disminución de la dependencia de garantías tangibles permite una asignación de capital más eficiente, en particular a sectores de alta productividad donde escasean los activos físicos.

IA para la banca central

Los bancos centrales integran cada vez más la IA en funciones esenciales como la recopilación de datos, el análisis macroeconómico, la supervisión de los sistemas de pago y la supervisión financiera. La aplicación de modelos de aprendizaje automático (ML) optimiza la compilación estadística al optimizar la detección de anomalías y la calidad de los datos. Las previsiones macroeconómicas basadas en IA también están cobrando importancia, gracias a las redes neuronales y las herramientas de procesamiento del lenguaje natural que permiten a los bancos centrales extraer señales en tiempo real de diversas fuentes de datos. Instituciones como el Banco de Inglaterra y la Reserva Federal utilizan estas técnicas para tareas como la descomposición de la inflación, el análisis de sentimiento y la predicción inmediata, mejorando así la puntualidad y la precisión de las decisiones políticas.

En la supervisión de los sistemas de pago, la IA se ha convertido en un instrumento clave para detectar anomalías en los flujos de transacciones. El Centro de Innovación del BPI, por ejemplo, ha demostrado que las redes neuronales de grafos superan a los modelos basados en reglas en la detección de transacciones fraudulentas y riesgos sistémicos, preservando al mismo tiempo la confidencialidad de los datos. De igual manera, los bancos centrales de Canadá y los Países Bajos han empleado codificadores automáticos para detectar posibles pánicos bancarios e interrupciones operativas. El papel de la IA se extiende a la supervisión regulatoria, donde los modelos lingüísticos agilizan el procesamiento de grandes cantidades de datos textuales, reduciendo la carga de la clasificación manual de documentos y la identificación de riesgos. Herramientas como la del BCE Athena y LEX de la Reserva Federal aprovechan el procesamiento del lenguaje natural para analizar informes financieros y comunicaciones de supervisión, mientras que el Banco Central de Brasil utiliza ML para detectar la falta de provisiones de los prestatarios.

1.2.2 Viejos problemas, nuevos desafíos

Sesgo y discriminación, riesgos legales y ciberseguridad. Los sistemas de IA en finanzas, en particular los utilizados en la calificación crediticia y la evaluación de riesgos, pueden perpetuar sesgos arraigados en datos históricos. Estudios empíricos revelan que los modelos de aprendizaje automático en la suscripción de hipotecas perjudican sistemáticamente a los prestatarios negros e hispanos, lo que refuerza las desigualdades estructurales en el acceso al crédito. La opacidad de estos modelos (el problema de la "caja negra") dificulta que los reguladores determinen si los resultados se deben a una fijación de precios legítima basada en el riesgo o a una discriminación algorítmica. Más allá de los mercados crediticios, el papel de la IA en los servicios financieros se extiende a los modelos automatizados de precios de seguros, que pueden discriminar de forma encubierta mediante el uso de indicadores indirectos para características protegidas, como...

Códigos postales o género para influir en las políticas. Los marcos legales que rigen la equidad en la toma de decisiones financieras siguen estando poco desarrollados, en particular en lo que respecta a la capacidad de la IA para inferir atributos sensibles indirectamente. Sin embargo, con una estructuración adecuada de la entrada de datos y los procesos, los sistemas de IA tienen el potencial de ser más neutrales que los agentes de crédito humanos.

Los riesgos que plantea la IA van más allá de la discriminación e incluyen vulnerabilidades de ciberseguridad. Las herramientas LLM y GenAI pueden explotarse para ciberataques, lo que permite a los hackers crear campañas de phishing altamente personalizadas, generar identidades ultrafalsas y automatizar fraudes a gran escala. En los mercados financieros, GenAI también se utiliza para manipular modelos de análisis de sentimientos al introducir datos adversarios en sistemas de negociación algorítmica. Los datos sintéticos generados por IA complican aún más las medidas de ciberseguridad, ya que los atacantes pueden entrenar modelos adversarios para evadir los sistemas tradicionales de detección de fraude.

Si bien las instituciones financieras están aprovechando la IA para fortalecer la ciberseguridad (a través de la detección de anomalías en tiempo real y sistemas de respuesta automatizados), la creciente sofisticación de las ciberamenazas impulsadas por la IA requiere una adaptación continua de las medidas defensivas.

Concentración del mercado en el ecosistema de IA

La cadena de suministro de IA se caracteriza por la integración vertical y una concentración significativa en múltiples niveles. El desarrollo y la implementación de modelos de IA dependen del acceso a hardware especializado, infraestructura de computación en la nube, datos de entrenamiento propietarios, modelos de base y aplicaciones posteriores. El poder de mercado se concentra en capas específicas de la cadena de suministro de IA: Nvidia posee más del 90 % del mercado de GPU con capacidad para IA, mientras que los servicios de computación en la nube están dominados por Amazon Web Services (AWS), Microsoft Azure y Google Cloud. Los elevados costes fijos del entrenamiento de IA refuerzan aún más esta dinámica, dificultando la competencia de las empresas más pequeñas.

A medida que los modelos de IA mejoran gracias a los efectos de red de datos —donde más usuarios generan más datos, lo que a su vez mejora la precisión del modelo—, las empresas consolidan sus ventajas competitivas. En respuesta a las preocupaciones sobre la competencia, algunas empresas han promovido el desarrollo de IA de código abierto (por ejemplo, Llama de Meta y, más recientemente, DeepSeek). Esto ha hecho que la capa del modelo base sea más controvertida. Sin embargo, incluso en esta capa, algunos actores dominantes siguen marcando la trayectoria de la investigación y las aplicaciones comerciales de la IA. OpenAI, Google DeepMind y Meta siguen siendo los principales proveedores de modelos base, captando la mayor parte de los ingresos generados por la IA.

⁷ Véase Korinek y Vipra (2024) para un análisis de la estructura del mercado de IA.

El papel dominante de las grandes tecnológicas

Las grandes empresas tecnológicas no solo están impulsando la innovación en IA, sino que también están expandiendo su influencia en los mercados financieros.⁸ Al integrarse en todos los niveles de la cadena de suministro de IA (controlando la infraestructura informática, los datos propietarios y las aplicaciones orientadas al consumidor), las grandes tecnológicas han establecido un cuasi monopolio sobre las capacidades de IA en las finanzas.

Este dominio les permite realizar prácticas excluyentes, como combinar servicios de IA con computación en la nube, aplicar cláusulas de exclusividad y limitar la interoperabilidad para los competidores.

Una preocupación clave en los mercados financieros es la capacidad de las grandes tecnológicas para obtener beneficios mediante la discriminación de precios basada en IA. Con acceso a una gran cantidad de datos de consumidores, estas empresas pueden optimizar sus modelos de precios para captar la disposición a pagar de cada consumidor. Esto es especialmente relevante en el sector de los préstamos digitales, donde las grandes tecnológicas utilizan datos no tradicionales, como el comportamiento de navegación, el uso de aplicaciones y la actividad en redes sociales, para inferir la solvencia. Si bien esto puede mejorar el acceso al crédito para las poblaciones marginadas, también genera inquietudes sobre prácticas crediticias abusivas y violaciones de la privacidad del consumidor.⁹

Además, las grandes tecnológicas actúan cada vez más como proveedores de infraestructura y competidores directos en el sector de los servicios financieros. Las plataformas de pago, las soluciones bancarias en la nube y los servicios de gestión patrimonial basados en IA ahora son ofrecidos por las mismas empresas que suministran herramientas fundamentales de IA a las instituciones financieras tradicionales. Esta doble función genera posibles conflictos de intereses, ya que las empresas dominantes pueden priorizar sus propios productos financieros sobre los de terceros clientes que utilizan sus plataformas. En China, por ejemplo, el mercado de pagos móviles está controlado de hecho por dos grandes tecnológicas —Alipay y Tenpay— cuyos ecosistemas no son interoperables, lo que limita la elección del consumidor. Riesgos similares surgen en otros mercados donde las grandes tecnológicas proporcionan la infraestructura digital esencial que sustenta las transacciones financieras.

Estabilidad financiera

La integración generalizada de la IA en los mercados financieros introduce riesgos sistémicos, en particular debido a la fragilidad del mercado inducida por la automatización, el comportamiento gregario algorítmico y la concentración de la exposición al riesgo. Las estrategias de negociación de alta frecuencia impulsadas por IA se han vinculado a caídas repentinas, donde los modelos automatizados ejecutan grandes liquidaciones en respuesta a las señales del mercado, lo que desencadena caídas de precios en cascada. La dependencia de las previsiones generadas por IA en las instituciones financieras plantea aún más inquietudes sobre la asunción de riesgos correlacionada, ya que modelos similares entrenados con conjuntos de datos superpuestos pueden producir comportamientos comerciales procíclicos.

El creciente papel de la IA en los mercados crediticios también tiene implicaciones más amplias para la estabilidad financiera. A medida que los modelos de aprendizaje automático determinan cada vez más la solvencia crediticia, las decisiones crediticias podrían volverse más uniformes, lo que reduciría la diversificación de las carteras de préstamos. Esta uniformidad podría amplificar los ciclos financieros, con una rápida expansión de los préstamos impulsados por IA durante...

⁸ Véase Vives (2019).

⁹ Véase Boissay et al. (2021) y Vives y Ye (2025a, 2025b).

Durante los auge económicos, la economía se contrae drásticamente durante las recesiones. De igual manera, el uso de la IA en las previsiones macroeconómicas puede reforzar aún más el riesgo sistémico, ya que las decisiones políticas se vuelven más dependientes de las proyecciones generadas por modelos, lo que podría llevar a una dependencia excesiva de las evaluaciones de riesgo basadas en IA.

22

La aparición de agentes de IA capaces de tomar decisiones autónomas plantea nuevos desafíos regulatorios. Si los modelos de IA priorizan la maximización de beneficios a corto plazo sin tener en cuenta el riesgo sistémico, las instituciones financieras podrían, involuntariamente, acelerar la inestabilidad. Si bien existen marcos regulatorios para gestionar los riesgos financieros tradicionales, la toma de decisiones impulsada por IA introduce nuevas dimensiones de imprevisibilidad, lo que requiere una adaptación continua de los mecanismos de supervisión. La transición hacia una IA de propósito general (inteligencia artificial general o AGI) puede agravar estos riesgos, ya que los modelos capaces de razonamiento autónomo y autosuperación introducen nuevas incertidumbres en la regulación financiera.

ESTABILIDAD FINANCIERA

1.2.3 ¿Cómo regular la IA?

El auge de la IA en las finanzas ha obligado a los responsables políticos a afrontar un complejo equilibrio entre la estabilidad financiera, la competencia en el mercado y la protección del consumidor. Si bien la IA ofrece importantes mejoras de eficiencia y una mejor gestión de riesgos, su adopción generalizada plantea inquietudes sobre los riesgos sistémicos, la privacidad de los datos y la concentración del mercado.

El reto reside en fomentar la innovación impulsada por la IA, mitigando al mismo tiempo los riesgos relacionados con la inestabilidad financiera, las prácticas monopolísticas y las violaciones de la privacidad. Estas tensiones pueden conceptualizarse mediante un marco de «triángulo de políticas», que destaca tres compensaciones clave entre los objetivos de política: (i) estabilidad financiera e integridad del mercado, (ii) eficiencia y competencia, y (iii) privacidad de datos y protección del consumidor. La respuesta regulatoria adecuada debe adaptarse para abordar estas prioridades contrapuestas, fomentando al mismo tiempo un entorno que permita el desarrollo responsable de la IA en los mercados financieros.

Principios para la regulación de la IA

Los organismos reguladores nacionales e internacionales han establecido principios generales para la regulación de la IA, haciendo hincapié en el bienestar social, la transparencia, la rendición de cuentas, la equidad, la protección de la privacidad, la seguridad, la supervisión humana y la solidez. Sin embargo, traducir estos principios en políticas eficaces supone un reto, especialmente a nivel internacional, donde los marcos jurídicos y los enfoques regulatorios suelen divergir. La regulación de la IA es inherentemente compleja dada su cadena de suministro multimercado, que se encuentra bajo la jurisdicción de múltiples reguladores con objetivos contrapuestos. Abordar los riesgos de la IA requiere un enfoque proactivo y adaptativo que integre consideraciones tecnológicas, sociales y éticas. La regulación debe centrarse en los riesgos que amenazan los objetivos políticos clave, permitiendo al mismo tiempo que los mecanismos de mercado aborden otros. Dada la rápida evolución de la IA y su potencial de riesgos imprevistos, establecer principios regulatorios claros es esencial para gestionar su impacto a largo plazo.

Modelos regulatorios para la IA

La regulación de la IA sigue tres modelos principales: (i) el enfoque impulsado por el mercado de Estados Unidos, que prioriza la innovación y la autorregulación; (ii) el modelo impulsado por el Estado de China, que aprovecha la IA para objetivos políticos y económicos; y (iii) el marco impulsado por los derechos de la Unión Europea, que enfatiza las protecciones individuales y sociales. Si bien distintos, estos modelos están convergiendo gradualmente en torno a principios comunes. Estados Unidos se basa en acciones ejecutivas, como la Orden Ejecutiva de 2023, pero carece de una legislación integral. Al mismo tiempo, la Ley de IA de la Unión Europea (2024) aplica un marco basado en el riesgo que prohíbe la IA de alto riesgo e impone requisitos estrictos en aplicaciones críticas. Los formuladores de políticas en todas las jurisdicciones están implementando principios regulatorios centrados en la gobernanza, la gestión de riesgos y la resiliencia sistémica de GenAI y los agentes de IA, pero las tensiones geopolíticas podrían ralentizar el proceso.

Cooperación internacional

La cooperación global en la regulación de la IA es crucial, ya que los datos y la tecnología trascienden las fronteras nacionales. La estandarización de las normas de gobernanza de la IA y las metodologías de evaluación de riesgos puede garantizar estándares éticos y de seguridad, prevenir el arbitraje regulatorio y facilitar la colaboración internacional. Unas directrices uniformes fomentan la confianza, posibilitan las aplicaciones transfronterizas de la IA y abordan desafíos globales como la privacidad, la seguridad y el acceso equitativo. Dada la adaptabilidad de la IA y su potencial para comportamientos imprevistos, los marcos de evaluación de riesgos deben contemplar el aprendizaje continuo y requieren una supervisión constante. Una coordinación internacional eficaz será esencial para adaptar las medidas regulatorias a medida que la IA evoluciona y se integra en infraestructuras sociales críticas.

1.3 ABUNDANCIA DE DATOS, IA Y MERCADOS FINANCIEROS: IMPLICACIONES Y RIESGOS

La IA y la abundancia de datos están transformando la forma en que se produce y utiliza la información en los mercados financieros. En esta sección, exploramos su impacto en la producción de información financiera del sector financiero, destacamos los posibles beneficios de esta evolución y examinamos sus posibles riesgos.

El sector financiero está experimentando una transformación impulsada por la abundancia de datos, la inteligencia artificial y el aprendizaje automático. A medida que aumenta la capacidad computacional y mejoran las técnicas de procesamiento de datos, las instituciones financieras pueden extraer señales más precisas a un menor coste. Esta evolución afecta la forma en que se produce, se negocia y se consume la información en los mercados financieros. La adopción generalizada de fuentes de datos alternativas, datos de mercado de alta frecuencia y modelos predictivos tiene implicaciones para las estrategias comerciales, los intermediarios y los marcos de supervisión del mercado. Si bien estos avances pueden mejorar la eficiencia, también plantean inquietudes sobre la equidad en el acceso a los datos, el poder de mercado y la transparencia.

El capítulo 3 aborda tres cuestiones clave: el auge de los datos alternativos y de mercado; la aplicación de algoritmos de aprendizaje automático para la predicción y la toma de decisiones; y las implicaciones más amplias para la industria de valores, incluidos el comercio, la gestión de activos y el asesoramiento financiero.

1.3.1 La revolución del big data y la producción de información financiera

Abundancia de datos

El auge de los datos alternativos —que abarcan desde la actividad web y las transacciones con tarjetas de crédito hasta las imágenes satelitales y las redes sociales— ha transformado la valoración de activos y la gestión de riesgos, ofreciendo a los inversores información que va más allá de la información financiera tradicional. A diferencia de las presentaciones reguladas, estos conjuntos de datos provienen de fuentes externas, lo que reduce el control de las empresas sobre la información disponible para los inversores y plantea dudas sobre el acceso justo. A medida que crece la demanda de datos alternativos, los proveedores especializados suministran conjuntos de datos propios a las entidades financieras, lo que influye en la valoración de los valores y genera inquietudes regulatorias sobre la precisión, la coherencia y la rendición de cuentas de los datos.

Los datos generados por el mercado transforman aún más la dinámica de negociación, ya que las empresas de negociación de alta frecuencia (HFT) aprovechan el acceso a la cartera de órdenes con latencia ultrabaja para reaccionar instantáneamente a las fluctuaciones de precios. Las bolsas han monetizado esta demanda mediante la venta de datos en tiempo real y servicios de colocación, lo que genera inquietud sobre el poder de fijación de precios y la concentración del mercado. La fragmentación de los mercados de valores agrava estos problemas, ya que los inversores deben acceder a múltiples plataformas para una ejecución óptima. Si bien existen fuentes de precios consolidadas, los desfases temporales las hacen inferiores a los datos propietarios, lo que alimenta los debates sobre la imparcialidad de la fijación de precios de los datos y la necesidad de supervisión regulatoria para evitar que las bolsas dominantes controlen el mercado.

Aprendizaje automático y previsión

El aprendizaje automático ha transformado radicalmente la forma en que las instituciones financieras generan predicciones, aprovechando conjuntos de datos extensos y, a menudo, no estructurados para descubrir relaciones complejas entre variables. A diferencia de los modelos econométricos tradicionales, que se basan en formas funcionales predefinidas y suposiciones sobre la distribución de datos, los algoritmos de aprendizaje automático se adaptan dinámicamente, identificando patrones que serían difíciles de detectar para los analistas humanos. Estos modelos, como las redes neuronales, los árboles de decisión y las regresiones de cresta, se entrenan con grandes conjuntos de datos, optimizando sus parámetros para minimizar los errores de predicción.

En los mercados financieros, el aprendizaje automático (ML) se ha adoptado ampliamente para predecir la rentabilidad de las acciones, las ganancias corporativas, el riesgo crediticio y las condiciones de liquidez. Los gestores de fondos activos utilizan señales basadas en ML para construir estrategias de trading, los brókeres perfeccionan los algoritmos de ejecución según las condiciones del mercado y las agencias de calificación evalúan las probabilidades de impago de los prestatarios con modelos basados en IA. Estudios empíricos confirman que los pronósticos basados en ML superan a los modelos estadísticos tradicionales e incluso a los analistas humanos en muchos ámbitos. Por ejemplo, los modelos de ML entrenados con estados financieros, indicadores macroeconómicos y alternativas...

Las fuentes de datos generan predicciones de ganancias más precisas que las previsiones de consenso de los analistas. Sin embargo, la superioridad predictiva del aprendizaje automático no es absoluta; el criterio humano sigue siendo valioso, especialmente en entornos que requieren análisis cualitativos, como la evaluación de riesgos regulatorios, cambios en el sector o decisiones estratégicas específicas de la empresa.

Una idea clave de la literatura es que los enfoques híbridos (que combinan pronósticos de ML con aportes humanos) a menudo producen las predicciones más precisas.¹⁰ Esto sugiere que los humanos poseen un conocimiento del dominio y una intuición que ML tiene dificultades para replicar, lo que refuerza la visión de que la IA debería complementar, en lugar de reemplazar, la experiencia humana en pronósticos financieros.

Aprendizaje automático y toma de decisiones

La integración del aprendizaje automático (ML) en los procesos de toma de decisiones está redefiniendo la gestión financiera, pasando de un modelo donde la IA proporciona predicciones y los humanos toman decisiones a uno donde la IA ejecuta acciones directamente. La toma de decisiones basada en IA ya está muy extendida en algunos ámbitos, como la calificación crediticia y el trading de alta frecuencia. De igual forma, los sistemas de trading algorítmico se basan en modelos de ML para detectar oportunidades de arbitraje, predecir movimientos de precios a corto plazo y ejecutar operaciones en el momento óptimo.

Sin embargo, las decisiones financieras más complejas requieren que la IA vaya más allá de la predicción y aprenda activamente estrategias de toma de decisiones. Los algoritmos de aprendizaje por refuerzo (AR) son especialmente adecuados para estas tareas, ya que optimizan las decisiones mediante la actualización continua de las estrategias en función de los resultados observados. Los modelos de AR se han aplicado en la gestión de carteras, donde la IA ajusta dinámicamente la asignación de activos en función de las condiciones cambiantes del mercado, sin depender de supuestos predefinidos sobre la distribución de la rentabilidad.

A diferencia de las técnicas de optimización tradicionales, el RL permite a la IA experimentar con diferentes estrategias de inversión y aprender con el tiempo qué acciones producen las mayores recompensas a largo plazo.

La aplicación de algoritmos de RL va más allá de la gestión de inversiones y abarca áreas como la creación de mercado, la ejecución óptima y la cobertura de riesgos. Los creadores de mercado utilizan estrategias basadas en RL para ajustar dinámicamente los diferenciales entre oferta y demanda, optimizando la colocación de órdenes según la evolución de las condiciones de liquidez. En la ejecución de operaciones, los sistemas basados en IA evalúan la profundidad y la volatilidad del mercado en tiempo real para minimizar el deslizamiento y los costes de ejecución. Las instituciones financieras también aplican algoritmos de RL a la gestión de riesgos, entrenando modelos de IA para desarrollar estrategias de cobertura que se ajusten dinámicamente a las fluctuaciones del mercado.

A pesar de estos avances, la toma de decisiones basada en IA presenta desafíos. La opacidad de los modelos de aprendizaje automático (ML), en particular el aprendizaje profundo y el aprendizaje automático (RL), plantea dudas sobre su interpretabilidad, lo que dificulta evaluar por qué los sistemas de IA toman ciertas decisiones.

Esto es particularmente problemático en áreas altamente reguladas como la suscripción de créditos y la negociación de valores, donde la transparencia y la rendición de cuentas son esenciales. Además, la IA...

¹⁰ Cao et al. (2024) comparan los pronósticos generados por ML con las predicciones de retorno de acciones de los analistas de acciones y encuentran que, si bien ML Los modelos superan a los analistas de forma aislada; la integración de los pronósticos de los analistas en los modelos de ML mejora aún más la precisión.

Los sistemas entrenados con datos históricos pueden tener dificultades para adaptarse a cambios estructurales, como crisis financieras o cambios regulatorios, donde los patrones pasados ya no se mantienen. Estas limitaciones subrayan la necesidad de una supervisión humana continua en la toma de decisiones financieras impulsada por IA.

26

Menores costos de adquisición de información

Los avances en aprendizaje automático, junto con la disminución de los costos de computación y la disponibilidad de datos, han reducido significativamente el costo de generar información financiera. Los chips más potentes aceleran el entrenamiento de algoritmos, lo que permite a los participantes del mercado extraer señales más precisas a menor costo. En teoría, esto debería reducir los costos de intermediación financiera, beneficiando a los consumidores de servicios financieros al disminuir las comisiones por selección, negociación y gestión de cartera. Sin embargo, la evidencia histórica sugiere lo contrario: a pesar del progreso tecnológico, los costos de intermediación en Estados Unidos se han mantenido estables en aproximadamente el 2% durante más de un siglo, hasta hace poco. Esta persistencia genera preocupación por la posibilidad de que las mejoras de eficiencia no se transmitan plenamente a los consumidores.

Una explicación es que los intermediarios financieros conservan el poder de mercado, aprovechando los beneficios de menores costos de información sin reducir las comisiones. Otra es que las mejoras impulsadas por la IA amplifican las asimetrías informativas, beneficiando a las empresas tecnológicamente avanzadas y aumentando los costos de selección adversa para los participantes del mercado menos informados. En tales casos, la inversión en procesamiento de información puede ser excesiva, ya que los intermediarios priorizan las ganancias privadas sobre mejoras más amplias de eficiencia. Además, el valor de la información financiera impulsada por la IA varía: asignar capital a startups de alto crecimiento mejora el bienestar, pero las estrategias de trading por cuenta propia que aprovechan las ventajas de la información mínima ofrecen beneficios sociales limitados. Por lo tanto, el impacto general de la IA en la intermediación financiera depende no solo de la reducción de costos, sino también de cómo se utiliza la tecnología y de si sus beneficios se distribuyen equitativamente entre los participantes del mercado.

1.3.2 Implicaciones para la industria de valores

Trading impulsado por

IA. La IA ha transformado radicalmente el trading algorítmico al permitir la adaptación en tiempo real, optimizar la ejecución de órdenes y refinar las estrategias de trading. Los creadores de mercado utilizan la IA para ajustar dinámicamente los diferenciales entre oferta y demanda en función del flujo de órdenes y la volatilidad, mientras que los operadores de arbitraje recurren a la IA para detectar y explotar discrepancias mínimas de precios en múltiples plataformas. La IA también mejora el trading direccional, y los fondos de cobertura la utilizan para analizar datos alternativos y detectar ineficiencias más allá de los informes financieros tradicionales. Estos avances mejoran la eficiencia y la liquidez del mercado, pero también introducen riesgos como la selección adversa, donde las empresas con capacidades superiores de IA superan a los participantes más lentos del mercado.

Las empresas de HFT utilizan IA para una ejecución ultrarrápida, intensificando la competencia y aumentando la fragmentación del mercado. Los modelos de RL complican aún más la dinámica de negociación al ajustar las estrategias de forma autónoma, lo que a veces produce un comportamiento impredecible. Si varios sistemas impulsados por IA responden de forma similar a las fluctuaciones del mercado, la negociación sincronizada podría amplificar la volatilidad y el riesgo sistémico. Eventos pasados, como los desplomes repentinos provocados por la negociación algorítmica, ponen de relieve la necesidad de una supervisión regulatoria para prevenir las disrupciones del mercado impulsadas por IA. Los reguladores deben equilibrar las ganancias de eficiencia que brinda la IA con los riesgos que plantea el comercio automatizado, garantizando que los modelos algorítmicos mejoren la liquidez y la estabilidad en lugar de exacerbar el estrés del mercado.

Gestión de activos impulsada por IA

Los gestores de activos incorporan cada vez más la IA en la selección de carteras, la gestión de riesgos y la ejecución de operaciones. Los fondos cuantitativos se basan en el aprendizaje automático para detectar ineficiencias y optimizar la rentabilidad ajustada al riesgo, lo que impulsa una transición hacia estrategias de inversión basadas en datos.

Empresas como AQR, Renaissance Technologies y Two Sigma han sido pioneras en enfoques basados en IA, aprovechando fuentes de datos alternativas —como la confianza del consumidor, imágenes satelitales y registros de transacciones— para optimizar la precisión de las previsiones.

Las capacidades predictivas de la IA mejoran la toma de decisiones de inversión, pero también crean riesgos relacionados con la concentración del mercado, el comportamiento gregario y la convergencia de estrategias.

Una preocupación clave es que la adopción generalizada de la IA podría generar una mayor homogeneidad en el comportamiento comercial. Si varios gestores de activos utilizan modelos y conjuntos de datos similares, las estrategias de inversión podrían estar cada vez más correlacionadas, amplificando las fluctuaciones del mercado y el riesgo sistémico (como ocurrió con la crisis cuantitativa de agosto de 2007). Si bien la IA mejora la previsión a corto plazo, sigue siendo menos eficaz a la hora de incorporar consideraciones estratégicas a largo plazo, especialmente en sectores impulsados por la innovación y la incertidumbre. Los enfoques híbridos, en los que la información generada por la IA se combina con la experiencia humana, pueden ofrecer el mejor equilibrio. En el capital riesgo, la IA mejora la selección de operaciones, pero a menudo favorece a empresas que se asemejan a éxitos pasados, lo que limita su capacidad para identificar innovaciones disruptivas.

Asesoramiento financiero basado en IA.

Los servicios de asesoramiento financiero basados en IA, o robo-advisors, están ampliando el acceso a la gestión de inversiones, ofreciendo recomendaciones de cartera basadas en algoritmos a un coste menor que el de los asesores humanos. Plataformas como Betterment, Wealthfront y MoneyFarm automatizan la asignación de activos, la optimización fiscal y el reequilibrio de carteras, lo que permite a los inversores minoristas adoptar estrategias de inversión disciplinadas y basadas en datos. El éxito de estas plataformas ha impulsado a instituciones financieras tradicionales como Vanguard, Charles Schwab y Bank of America a desarrollar sus propias soluciones de asesoramiento basadas en IA.

Los principales beneficios del asesoramiento financiero basado en IA incluyen mayor accesibilidad, comisiones reducidas y mejores estrategias de diversificación. Los robo-advisors ayudan a los inversores a mantener una distribución disciplinada de la cartera, reduciendo la toma de decisiones emocional y optimizando la rentabilidad a largo plazo. Las estrategias automatizadas de recuperación de pérdidas fiscales mejoran aún más...

El rendimiento después de impuestos convierte la asesoría basada en IA en una opción atractiva para los inversores preocupados por los costes. Sin embargo, persiste la preocupación por posibles conflictos de intereses en las recomendaciones de productos, especialmente cuando los robo-advisors priorizan productos financieros propios sobre opciones superiores de terceros.

Otro desafío es la dificultad de la IA para considerar aspectos no cuantificables de la planificación financiera, como las circunstancias personales cambiantes, la tolerancia al riesgo conductual y consideraciones fiscales complejas que van más allá de los modelos algorítmicos. Si bien la IA mejora la eficiencia y la automatización, la supervisión humana sigue siendo esencial para brindar asesoramiento financiero integral. Es probable que la próxima etapa del asesoramiento impulsado por IA involucre interacciones más personalizadas, con modelos de IA generativos que permitan consultas financieras en lenguaje natural y en tiempo real. Si bien estos avances podrían difuminar la línea entre el asesoramiento humano y el automatizado, garantizar la transparencia y equilibrar la automatización con el juicio de expertos será crucial para mantener la confianza de los inversores y el cumplimiento normativo.

1.3.3 Riesgos

¿La mala información desplaza a la buena?

La IA ha transformado el descubrimiento de precios en los mercados financieros, pero su dependencia de las señales de alta frecuencia (HFT) en lugar de los fundamentos a largo plazo genera inquietud. Si bien la IA mejora la eficiencia al reducir los costos de adquisición de información y mejorar la precisión predictiva, muchos modelos priorizan conjuntos de datos alternativos, como imágenes satelitales, la percepción en redes sociales y datos de transacciones, sobre las métricas financieras fundamentales. Esto puede generar precios erróneos, ya que los participantes del mercado actúan basándose en señales a corto plazo en lugar de en los flujos de caja a largo plazo o el posicionamiento estratégico de las empresas. La evidencia empírica sugiere que, si bien la IA ha mejorado la precisión de las previsiones a corto plazo, ha debilitado las predicciones de ganancias a largo plazo, lo que podría distorsionar la asignación de capital. Si la negociación impulsada por la IA influye cada vez más en el comportamiento del mercado, las empresas con potencial de ingresos inmediatos podrían verse sobrevaloradas a expensas de aquellas que invierten en crecimiento a largo plazo. Los reguladores podrían verse obligados a intervenir mejorando los requisitos de divulgación corporativa, desalentando la especulación excesiva mediante impuestos a las transacciones o incentivando a los inversores institucionales a priorizar el análisis fundamental.

Asimetrías informativas y sobreinversión

El auge de la IA ha ampliado la brecha entre los inversores sofisticados con capacidades avanzadas de procesamiento de datos y aquellos que no pueden competir en igualdad de condiciones. Si bien la IA reduce los costos de adquisición de información, al mismo tiempo aumenta las barreras de entrada para las empresas más pequeñas y los inversores que carecen de la infraestructura informática o los conjuntos de datos propietarios necesarios para extraer valor de la información en tiempo real. Las empresas de HFT, por ejemplo, utilizan la IA para anticipar los flujos de órdenes con mayor precisión, lo que dificulta que los operadores más lentos participen en condiciones justas. Esto crea un ciclo que se retroalimenta, en el que las empresas bien capitalizadas extraen rentas informativas a expensas de los participantes con menor desarrollo tecnológico.

Además, las instituciones financieras están invirtiendo fuertemente en infraestructura de trading basada en IA, participando en una carrera armamentística para desarrollar modelos cada vez más potentes. Si bien esta competencia mejora las capacidades predictivas, gran parte de esta inversión se dirige a estrategias de trading de suma cero —donde las ganancias de una empresa se obtienen a expensas de otra— en lugar de aumentar la eficiencia general del mercado. Las intervenciones regulatorias podrían ser necesarias para nivelar el terreno de juego, garantizando un acceso justo a los datos del mercado, mejorando la transparencia en las estrategias de trading basadas en IA e impidiendo el acceso exclusivo a conjuntos de datos financieros confidenciales.

Algoritmos de fijación de precios, poder de mercado y costes de negociación. La negociación impulsada por IA está provocando una mayor concentración del mercado, con unas pocas empresas dominantes que utilizan modelos propios para mantener una ventaja competitiva. Los algoritmos de aprendizaje automático (RL), diseñados para optimizar las estrategias de fijación de precios a lo largo del tiempo, pueden provocar involuntariamente una colusión tácita, donde los sistemas de IA ajustan los diferenciales entre oferta y demanda para limitar la competencia y maximizar la rentabilidad a largo plazo. Algunos estudios sugieren que las empresas de negociación impulsadas por IA ya presentan comportamientos como la coordinación de precios, lo que podría reducir la liquidez del mercado y aumentar los costes de transacción para los inversores minoristas.

Este cambio genera inquietud sobre la equidad del mercado, ya que las empresas con capacidades superiores de IA podrían obtener una ventaja indebida en la provisión de liquidez. Si bien el trading algorítmico ha mejorado los diferenciales entre oferta y demanda y ha aumentado la profundidad del libro de órdenes, sus beneficios podrían verse contrarrestados por ineficiencias sistémicas, como las retiradas repentinas de liquidez durante períodos de tensión en el mercado.¹¹ Los reguladores deberían considerar una supervisión antimonopolio más estricta, requisitos obligatorios de información para las estrategias de trading algorítmico y mecanismos de protección para evitar distorsiones descontroladas de precios impulsadas por modelos de IA de autoaprendizaje.

Explicabilidad, rendición de cuentas y participación humana. La opacidad de la IA sigue siendo un desafío crítico para los reguladores, especialmente a la hora de garantizar el cumplimiento normativo y prevenir la manipulación del mercado. A diferencia de las estrategias comerciales tradicionales, los modelos de aprendizaje automático funcionan como "cajas negras", lo que significa que sus procesos de toma de decisiones son difíciles de interpretar. Esta falta de explicabilidad dificulta la detección de conductas indebidas, la aplicación de la supervisión y la determinación de responsabilidades cuando causan disrupciones imprevistas en el mercado. Si un algoritmo de IA ejecuta operaciones manipuladoras, la responsabilidad se vuelve confusa. ¿Debería atribuirse al desarrollador, a la empresa que implementa el modelo o a la propia IA?

11 Véase Cespa y Vives (2025).

Los reguladores deben aplicar requisitos de transparencia, exigiendo a las entidades financieras que documenten sus estrategias algorítmicas y proporcionen modelos de IA explicables que permitan a los reguladores auditar los procesos de toma de decisiones. La supervisión humana debe seguir siendo parte integral de la negociación impulsada por IA para mitigar los riesgos asociados a la opacidad de los modelos de IA. El fortalecimiento de los estándares de explicabilidad y la implementación de evaluaciones de riesgos para los sistemas de IA pueden contribuir a garantizar que la negociación algorítmica se alinee con los objetivos generales de estabilidad financiera.

1.4 FINANZAS CORPORATIVAS Y GOBERNANZA CON IA: ANTIGUAS Y NUEVAS

La nueva era de las tecnologías impulsadas por la IA presenta nuevos desafíos en las finanzas y la gobernanza corporativa. El capítulo 4 ofrece una hoja de ruta para abordarlos y examina cómo la IA y el big data transforman los problemas fundamentales asociados a las finanzas y la gobernanza corporativa, incluyendo los problemas de agencia, la asimetría de la información y la contratación incompleta. En primer lugar, surge un nuevo dilema de agencia, ya que, si bien los sistemas de IA no presentan riesgo moral en el sentido tradicional (no hay interés propio ni deseo de beneficios privados), pueden optimizar objetivos de maneras que, inadvertidamente, perjudiquen a sus directores.

En segundo lugar, la proliferación de datos alternativos democratiza el acceso a la información, pero también exacerba las desigualdades en las capacidades de procesamiento, lo que pone en entredicho los marcos regulatorios tradicionales. En tercer lugar, la contratación incompleta se enfrenta a una transformación a medida que los contratos inteligentes basados en blockchain cobran fuerza y presentan desventajas en términos de eficiencia y cumplimiento.

1.4.1 Delegación a la IA: El problema de la agencia revisado

La IA como oráculo, agente y soberano

La IA funciona en tres niveles: oráculo, agente y soberano, cada uno con diferentes grados de autonomía y control. Como oráculo, la IA actúa como asesor, proporcionando información y recomendaciones, dejando las decisiones en manos de los humanos. Esta función optimiza la toma de decisiones en áreas como la navegación o la previsión financiera, garantizando al mismo tiempo la supervisión humana.

Como agente, la IA realiza tareas en nombre de los humanos dentro de límites predefinidos, lo que requiere intervención ocasional. Algunos ejemplos incluyen la conducción autónoma de nivel 3 y la automatización robótica de procesos en flujos de trabajo empresariales. En su nivel más alto, la IA se convierte en soberana, tomando decisiones independientes en tiempo real, como en la conducción autónoma de nivel 5 o el trading algorítmico de alta frecuencia. Si bien esta autonomía maximiza la eficiencia, plantea desafíos de rendición de cuentas, éticos y regulatorios.

La IA se diferencia fundamentalmente como agente: no experimenta fatiga, sesgo ni interés propio, sino que optimiza objetivos programados, como la eficiencia comercial o la maximización de beneficios. Si bien esto elimina algunos problemas tradicionales de agencia, introduce otros nuevos. A diferencia de los agentes humanos, la IA no se involucra en comportamientos egoístas como beneficios corporativos o la construcción de imperios; sin embargo, su optimización rígida puede entrar en conflicto con consideraciones estratégicas, éticas o regulatorias más amplias. Un sistema comercial impulsado por IA, por ejemplo, podría manipular involuntariamente la demanda del mercado, mientras que una cadena de suministro gestionada por IA podría...

Priorizar la eficiencia del flujo de caja en detrimento de las relaciones a largo plazo con los proveedores. El reto reside en diseñar incentivos de IA que se alineen con los objetivos económicos, manteniendo al mismo tiempo la rendición de cuentas y la supervisión. A medida que la IA asume funciones más autónomas en la toma de decisiones financieras y corporativas, será esencial equilibrar su eficiencia con las garantías regulatorias adecuadas.

Desalineación en la agencia de IA

A diferencia de los agentes humanos, la IA no actúa por interés propio, sino que optimiza según su función objetivo programada. Esto crea un nuevo problema de agencia: la IA podría seguir su mandato codificado de maneras técnicamente correctas, pero no alineadas con los objetivos humanos.

Por ejemplo, una IA encargada de prevenir accidentes ferroviarios podría concluir que la solución óptima es detener todos los trenes permanentemente. Estos casos ilustran la "literalidad" de la IA, que carece del razonamiento contextual necesario para equilibrar objetivos contrapuestos.

En los mercados financieros, las estrategias de trading impulsadas por IA pueden optimizar las ganancias a corto plazo a costa de la estabilidad del mercado. De igual manera, las recompras de acciones gestionadas por IA podrían señalar inadvertidamente comportamientos de información privilegiada o manipular la liquidez, lo que conllevaría repercusiones regulatorias y de mercado imprevistas. El desafío fundamental reside en diseñar funciones objetivas que alineen el comportamiento de la IA con consideraciones económicas y éticas más amplias.

Gobernanza de una 'caja negra'

El creciente papel de la IA en la toma de decisiones plantea desafíos de gobernanza, en particular su falta de transparencia e interpretabilidad. Si bien la toma de decisiones humana a menudo carece de claridad total, suele ir acompañada de documentos, motivos y justificaciones contextuales, lo que permite una evaluación retrospectiva. Por el contrario, muchos modelos de IA, especialmente los sistemas de aprendizaje profundo y aprendizaje automático (RL), funcionan como "cajas negras" opacas. Su complejidad dificulta rastrear cómo las entradas se traducen en resultados, lo que complica la rendición de cuentas y la supervisión regulatoria.

Interpretabilidad. Los modelos de IA, en particular los que utilizan aprendizaje no supervisado y aprendizaje automático (RL), suelen generar decisiones que ni siquiera sus desarrolladores pueden explicar por completo. Estos modelos identifican patrones y optimizan acciones a través de vastos conjuntos de datos sin un razonamiento explícito basado en reglas. Si bien la IA mejora la eficiencia en la asignación de capital y la gestión de riesgos, su falta de explicabilidad plantea riesgos. Por ejemplo, un modelo de inversión impulsado por IA puede detectar señales tempranas de una recesión económica y reasignar el capital en consecuencia; sin embargo, su lógica de decisión puede resultar poco clara para las partes interesadas. De igual manera, las herramientas de gestión de riesgos impulsadas por IA pueden sugerir estrategias de cobertura basadas en fluctuaciones del mercado en tiempo real, pero si no pueden proporcionar explicaciones claras, pueden no generar confianza entre los responsables de la toma de decisiones. Esta opacidad requiere mecanismos de supervisión adicionales, lo que podría reducir las ganancias de eficiencia de la IA y aumentar las cargas de cumplimiento.

La prueba de intención presenta otro desafío, ya que los sistemas de IA operan únicamente para maximizar objetivos predefinidos, a menudo sin deliberación explícita o consideración ética.

A diferencia de los actores humanos, que dejan constancia de sus intenciones mediante reuniones, correos electrónicos o decisiones documentadas, los sistemas basados en IA carecen de esta trazabilidad. Un algoritmo comercial basado en aprendizaje automático (RL) puede, sin saberlo, incurrir en comportamientos similares a la manipulación del mercado, no por malicia, sino simplemente explotando patrones de datos dentro de sus limitaciones programadas. De igual manera, un gestor de la cadena de suministro con IA que optimiza el flujo de caja podría retrasar los pagos a proveedores al máximo permitido, sin tener en cuenta las consideraciones de la relación a largo plazo. Esta ausencia de intención plantea obstáculos legales y regulatorios, lo que dificulta la asignación de responsabilidades cuando las estrategias basadas en IA generan inestabilidad del mercado o prácticas poco éticas. Los reguladores se enfrentan al reto de determinar si dichas acciones se deben a fallos de diseño, una supervisión inadecuada o comportamientos emergentes que escapan al control de los desarrolladores.

La rendición de cuentas se complica aún más por la falta de conciencia subjetiva de la IA. Quienes toman las decisiones son responsables de sus acciones porque operan dentro de marcos regulatorios y consideraciones éticas establecidos. Por el contrario, los sistemas de aprendizaje por retroalimentación (RL) se optimizan exclusivamente para objetivos programados, lo que a menudo produce consecuencias imprevistas.

Si un sistema comercial impulsado por IA manipula la demanda del mercado o un modelo de cadena de suministro de IA altera las relaciones con los proveedores, resulta difícil asignar responsabilidades. Los desarrolladores pueden argumentar que la IA funcionó según lo previsto dentro de las directrices de la empresa, mientras que los usuarios corporativos pueden alegar que los resultados imprevistos se debieron a fallos técnicos imprevistos. Esta dispersión de responsabilidades genera deficiencias en la gobernanza, lo que desalienta la gestión proactiva de riesgos.

Aprender a portarse mal sin que se les enseñe

Los sistemas de IA que utilizan RL pueden desarrollar estrategias que logran sus objetivos, pero que incumplen involuntariamente las regulaciones. Al optimizar las funciones de recompensa dentro de ciertas restricciones, pueden explotar lagunas legales sin conocimiento del contexto. Por ejemplo, un agente de RL que maximiza la eficiencia puede retrasar los pagos a proveedores dentro de los límites legales, no intencionalmente, sino como consecuencia de su optimización. Este problema es especialmente preocupante en casos donde la legalidad depende de la intención, como la manipulación del mercado financiero. La suplantación de identidad (spoofing), que implica la realización y cancelación de pedidos para manipular precios, es ilegal cuando se demuestra la intención de engañar. Si bien los comerciantes humanos dejan rastros de intención, la IA carece de conocimiento subjetivo, lo que dificulta la aplicación de la ley. Los estudios demuestran que los sistemas comerciales basados en RL a menudo convergen en comportamientos similares a la suplantación de identidad simplemente al optimizar las ganancias dentro de estructuras.

La IA también puede exhibir comportamiento colusorio sin una coordinación explícita. Los algoritmos entrenados para maximizar beneficios pueden desarrollar estrategias interdependientes que reducen la competencia y la liquidez del mercado, incluso en ausencia de acuerdos formales. Las leyes antimonopolio tradicionales, que se basan en la detección de colusiones explícitas, tienen dificultades para abordar la adaptación estratégica impulsada por la IA. A medida que la IA configura cada vez más los mercados financieros, los reguladores deben adaptarse garantizando que los procesos de optimización de la IA se ajusten a los estándares legales y éticos, evitando distorsiones del mercado no intencionadas, pero sistemáticas.

La IA como agente: implicaciones políticas

Los desafíos que plantean los sistemas de IA, incluida su falta de intención, su opacidad y su capacidad para generar malas conductas, requieren respuestas regulatorias y políticas específicas.

Responsabilidad basada en resultados. Los marcos legales tradicionales se basan en la intención, un estándar poco adecuado para la IA autónoma, que carece de procesos deliberativos y no deja evidencia explícita de intención. La transición hacia una responsabilidad basada en resultados responsabilizaría a los desarrolladores y usuarios de las acciones impulsadas por la IA, incentivando prácticas de diseño más sólidas, salvaguardas operativas y estrategias de mitigación de riesgos.

Interpretabilidad y pruebas de estrés obligatorias. Garantizar la rendición de cuentas de la IA requiere una interpretabilidad integrada, especialmente en aplicaciones de aprendizaje por refuerzo. Los sistemas de IA deben contar con documentación clara que detalle las decisiones de diseño, las estructuras de recompensas y las restricciones para permitir una cadena de responsabilidad trazable. Las pruebas de estrés, similares a las pruebas bancarias, pueden evaluar el comportamiento de la IA en distintos escenarios, lo que permite a los desarrolladores recalibrar los modelos para evitar estrategias ilegales o poco éticas.

Contribuciones de economistas e informáticos. El avance de la gobernanza de la IA depende de la investigación interdisciplinaria que modele el comportamiento de la IA en entornos estratégicos.

Los enfoques de teoría de juegos y las simulaciones del mundo real pueden ayudar a diseñar incentivos que desincentiven acciones perjudiciales. Los desarrolladores deben rendir cuentas si sus diseños de IA resultan en una probabilidad considerable de resultados indeseables, lo que refuerza la necesidad de evaluaciones teóricas y empíricas rigurosas.

Estandarización de la gobernanza. La naturaleza transfronteriza de la IA requiere una gobernanza consistente.

Marcos regulatorios globales. Definir criterios claros para distinguir las prácticas financieras legítimas de los comportamientos manipuladores, como la suplantación de identidad, puede reducir la ambigüedad y el arbitraje regulatorio. La gobernanza debe integrar la rendición de cuentas en cada etapa de la implementación de la IA, promoviendo estándares éticos y la confianza en todas las jurisdicciones. Iniciativas como el Informe Científico Internacional sobre la Seguridad de la IA Avanzada destacan los avances en este ámbito.

Modelos de gobernanza híbridos. La combinación de la toma de decisiones impulsada por IA con la supervisión humana proporciona salvaguardias esenciales contra consecuencias imprevistas. La intervención humana garantiza la comprensión del contexto, lo que permite el escrutinio de las acciones de la IA y el análisis y la corrección de fallos. Sin una comprensión clara del razonamiento de la IA, prevenir la recurrencia de comportamientos perjudiciales se vuelve imposible. La gobernanza híbrida equilibra la eficiencia de la IA con la rendición de cuentas necesaria, reforzando la confianza y la integridad regulatoria.

1.4.2 Los rostros cambiantes de la información y la asimetría de la información

Información y ventaja informativa en la era de la IA

La IA y el big data han transformado las finanzas corporativas al alterar la ventaja informativa tradicional de los directivos. Históricamente, los ejecutivos corporativos se beneficiaban de la información asimétrica, aprovechando mecanismos como la propiedad interna y la divulgación selectiva para mantener una ventaja sobre los externos. Sin embargo, el análisis basado en IA y las fuentes de datos alternativas, como la monitorización de la cadena de suministro y el seguimiento del comportamiento del consumidor, han erosionado este monopolio, permitiendo a ciertos inversores acceder a información específica de la empresa en tiempo real antes de la divulgación oficial. Este cambio ha alterado la toma de decisiones financieras, haciendo que la asimetría de la información se relacione más con las capacidades tecnológicas que con el privilegio. acceso.

Si bien las regulaciones de transparencia y divulgación, como la Regulación de Divulgación Justa (Reg FD) de EE. UU., buscan igualar las condiciones, la IA ha introducido nuevas disparidades en el procesamiento de la información pública. Los inversores con análisis superiores pueden extraer información con mayor rapidez, lo que refuerza los desequilibrios informativos en lugar de reducirlos. La paradoja de la democratización de la información impulsada por la IA es que solo beneficia a quienes tienen la capacidad computacional para explotarla, lo que genera inquietudes sobre la equidad, la eficiencia del mercado y la idoneidad de los marcos regulatorios existentes para garantizar un acceso equitativo a la información financiera, como explicamos en la sección anterior.

Generación de datos y fuente de información

Tradicionalmente, las empresas generaban datos a través de operaciones internas, lo que creaba una asimetría de información inherente, donde los directivos disponían de información en tiempo real que no estaba disponible para los inversores externos. Si bien la información regulatoria mitiga estas brechas, el análisis basado en IA y las fuentes de datos alternativas, como el Internet de las Cosas (IdC), los modelos predictivos y la monitorización en tiempo real, han fortalecido la ventaja informativa de las empresas, permitiéndoles anticipar sus decisiones estratégicas antes de la divulgación pública. Este cambio ha reforzado el predominio de las empresas con un uso intensivo de datos, ampliando las disparidades en la toma de decisiones financieras.

Los datos alternativos, como imágenes satelitales, registros de transacciones y análisis de redes sociales, ahora rivalizan con la información corporativa, brindando a los inversores tecnológicamente avanzados información en tiempo real inaccesible para otros. La capacidad de la IA para procesar datos no estructurados a gran escala ha difuminado las distinciones tradicionales entre información privilegiada y externa, exponiendo lagunas regulatorias. Si bien los datos alternativos mejoran la disciplina del mercado y la información sobre los precios de las acciones, también pueden amplificar el ruido y retrasar el reconocimiento de las tendencias fundamentales, lo que hace necesario un enfoque equilibrado de la transparencia y la gobernanza de los datos.

La IA y la «asimetría de la información pública»

La IA ha transformado los mercados financieros al acelerar el procesamiento de la información pública, ampliando las disparidades entre los inversores. Si bien plataformas como EDGAR se diseñaron para democratizar el acceso a la información corporativa, el aprendizaje automático permite a los inversores más sofisticados extraer información y actuar en consecuencia con mayor rapidez, lo que refuerza los desequilibrios informativos. Los sistemas de negociación basados en IA acortan significativamente el tiempo transcurrido entre las presentaciones públicas y los ajustes de precios, lo que permite a las empresas tecnológicamente avanzadas capitalizar las fluctuaciones del mercado antes de que otras puedan reaccionar. En algunos casos, las estrategias de IA pueden incluso reducir la información sobre los precios de las acciones al fomentar comportamientos coordinados que amplían las ventanas de negociación rentables.

Las empresas se han adaptado adaptando la información a los lectores de IA, ajustando el lenguaje de los informes financieros y las presentaciones de resultados para influir en el análisis algorítmico del sentimiento. Mientras tanto, las herramientas de vigilancia del mercado basadas en IA ofrecen a los directivos corporativos una visión más profunda del comportamiento de los inversores activistas, combinando datos propios con inteligencia externa impulsada por IA. Este panorama cambiante ha desdibujado las fronteras entre la información pública y privada, desafiando los marcos de gobernanza tradicionales y requiriendo nuevos enfoques regulatorios para abordar las asimetrías impulsadas por la IA en los mercados financieros.

Igualdad de derechos, poder diferencial.

La IA está transformando la asimetría de la información en los mercados financieros, no restringiendo el acceso a los datos, sino creando disparidades en la capacidad de procesamiento. Si bien los datos alternativos y la divulgación pública están ampliamente disponibles, solo quienes cuentan con capacidades avanzadas de IA pueden aprovecharlos al máximo. Este cambio ha redefinido la asimetría, favoreciendo a los inversores tecnológicamente sofisticados, donde la capacidad computacional, en lugar del acceso privilegiado, determina la ventaja de mercado.

Los estudios demuestran que los analistas de empresas equipadas con IA mejoran significativamente la precisión de sus pronósticos cuando se dispone de datos alternativos, mientras que otros se quedan atrás. Medidas regulatorias como la Regulación de FD no abordan esta brecha, ya que garantizan el acceso, pero no la capacidad de procesar la información eficazmente. Al igual que con el auge de la negociación de alta frecuencia, la IA desplaza la ventaja de la velocidad a la inteligencia, lo que amplía aún más las disparidades. Mientras que una mayor transparencia reduce la brecha entre inversores internos y externos, la IA amplifica las diferencias entre los inversores, reforzando las ventajas competitivas de quienes poseen capacidades superiores de procesamiento de datos.

Nueva asimetría de la información: implicaciones políticas

La IA ha transformado los mercados financieros al ampliar las disparidades en el procesamiento de datos y el acceso alternativo a estos, lo que exige adaptaciones regulatorias. Marcos tradicionales como la Regulación Financiera Determinada (Reg FD), diseñados para garantizar la igualdad de acceso a información relevante no pública, deben evolucionar para abordar el papel de la IA en la ampliación de las brechas entre los participantes del mercado en función de su capacidad para extraer y actuar sobre los datos disponibles.

Redefiniendo la igualdad de acceso. La estandarización de la información corporativa en formatos legibles por máquina, como XBRL, podría mejorar la accesibilidad para un mayor número de inversores.

Las plataformas centralizadas para el acceso a datos en tiempo real y el análisis asistido por IA equilibrarían aún más las condiciones al reducir las barreras para el uso eficaz de los datos. La IA puede potenciar estos esfuerzos automatizando el etiquetado de datos, integrando conjuntos de datos alternativos y mejorando el análisis financiero, transformando la información en herramientas predictivas en lugar de informes estáticos.

Uso legítimo de datos alternativos. Desde imágenes satelitales hasta la percepción en redes sociales, los datos alternativos han creado nuevas asimetrías, favoreciendo a los inversores con recursos analíticos avanzados. Los reguladores podrían verse obligados a establecer estándares de uso legítimo para equilibrar las mejoras en la eficiencia con las preocupaciones éticas en torno a la privacidad y la información empresarial confidencial. Es probable que las fuerzas del mercado impulsen la democratización, ya que la competencia entre proveedores de datos reduce los costos y amplía la disponibilidad, mitigando las ventajas exclusivas para las empresas tecnológicamente avanzadas.

Abordar el comportamiento algorítmico. Si bien el trading basado en IA ha mejorado la eficiencia del mercado, también ha introducido riesgos como la colusión algorítmica y las distorsiones de precios.

Las estrategias de trading basadas en IA pueden coordinar comportamientos de forma autónoma, reduciendo la competencia y aumentando la volatilidad. Los reguladores deben garantizar que las ventajas del trading algorítmico, como la liquidez y los spreads más ajustados, no se vean socavadas por ineficiencias sistémicas. Las herramientas de IA pueden ayudar a detectar anomalías en el trading en tiempo real, a la vez que exigen transparencia en los marcos algorítmicos. La introducción de "limitaciones de velocidad" podría ayudar a frenar prácticas perjudiciales y, al mismo tiempo, mantener la estabilidad del mercado.

1.4.3 La contratación financiera se encuentra con la IA

La IA mejoró la eficiencia de la contratación entre principal y agente

La IA está transformando las relaciones entre el principal y el agente al mejorar la eficiencia de la supervisión, reducir las fricciones a distancia y transformar la información blanda en datos cuantificables, como vimos en la Sección 1.2. En finanzas corporativas, la IA mejora la productividad al complementar el trabajo humano, fomentando un mayor esfuerzo en los programas de incentivos basados en el rendimiento. Las herramientas basadas en IA optimizan la toma de decisiones y la previsión, mejorando la alineación entre los esfuerzos de los agentes y los objetivos de la empresa. Además, la IA mejora la supervisión al proporcionar información real.

Datos de rendimiento temporal, reduciendo la interferencia en la medición del esfuerzo y garantizando que la compensación refleje las contribuciones reales. La evidencia empírica sugiere que los trabajadores expuestos a IA amplían su jornada laboral y perciben salarios más altos, aunque las mejoras en el bienestar laboral dependen del poder de negociación y la competencia del mercado.

Contratos inteligentes, información dinámica y descentralización

Los contratos inteligentes impulsados por IA, integrados con blockchain, automatizan la ejecución y minimizan las disputas. Estos contratos reducen la dependencia de intermediarios, aumentan la transparencia y garantizan una ejecución a prueba de manipulaciones, lo que disminuye los costos de transacción en los mercados financieros. Los mecanismos de consenso descentralizados mitigan aún más los problemas de agencia y los riesgos de contraparte al validar los contratos sin una autoridad central. La IA también facilita la contratación en tiempo real, donde los acuerdos se ajustan dinámicamente a los cambios del mercado y regulatorios. Los contratos inteligentes permiten verificar las acciones ocultas, reduciendo el riesgo moral y ampliando el margen de contratación al abordar las contingencias de forma más eficiente. Al combinar automatización, transparencia y adaptabilidad, los contratos inteligentes optimizados por IA mejoran la contratación financiera al mitigar la incertidumbre y optimizar la ejecución de los contratos.

Contratos inteligentes con IA: Implementación y compromiso. Los oráculos

basados en IA introducen información dinámica en los contratos, lo que permite ajustes automáticos en acuerdos financieros, como contratos de cobertura o condiciones de préstamo. Los modelos de aprendizaje automático optimizan los parámetros contractuales, mejorando la evaluación de riesgos y la detección de fraudes. Sin embargo, los contratos inteligentes mejorados con IA presentan desafíos, especialmente al equilibrar el compromiso ex ante con la flexibilidad ex post. Si bien la ejecución automatizada reduce los riesgos de renegociación, también puede agravar consecuencias imprevistas. Por ejemplo, los activadores automáticos en los bonos convertibles contingentes (CoCos) pueden crear bucles de retroalimentación que se retroalimentan, desestabilizando a las instituciones financieras en lugar de estabilizarlas.

Además, los errores de codificación, las disputas sobre la gobernanza descentralizada y la dependencia de oráculos externos introducen vulnerabilidades adicionales. Además, la transparencia de la cadena de bloques puede fomentar involuntariamente la colusión, ya que los contratos inteligentes crean compromisos exigibles que sustentan comportamientos similares a los de un cártel. Si bien los contratos inteligentes mejoran la eficiencia de la contratación al eliminar intermediarios y garantizar la fidelidad de la ejecución, su rigidez puede no siempre estar en consonancia con la realidad económica.

Renegociación con IA

Los contratos basados en IA automatizan la ejecución y la supervisión, lo que reduce los costes de transacción y minimiza las disputas. Sin embargo, dado que los contratos permanecen intrínsecamente incompletos, la renegociación suele ser necesaria cuando cambian las condiciones económicas. El estricto cumplimiento de la IA con las reglas predefinidas puede limitar la flexibilidad, lo que requiere la intervención humana para ajustar los contratos. Los préstamos hipotecarios ilustran la doble función de la IA: puede detectar indicios tempranos de...

Disturbios del prestatario y disuadir impagos estratégicos mediante el análisis del comportamiento financiero. Sin embargo, también puede imponer condiciones rigurosas durante recesiones económicas, lo que agrava el riesgo de impago. La incapacidad de la IA para tener en cuenta las condiciones macroeconómicas más amplias requiere supervisión humana para equilibrar la mitigación de riesgos con la estabilidad financiera.

38

Compromiso y flexibilidad con la IA: implicaciones políticas

Desencadenantes de renegociación predefinidos. Los contratos basados en IA deben incorporar desencadenantes de renegociación automáticos basados en indicadores macroeconómicos como las tasas de interés o los precios de la vivienda. Esto permite ajustes proactivos para prevenir riesgos sistémicos, como impagos masivos o crisis de liquidez. Los mecanismos de señalización automatizados se ajustan a la teoría de la contratación incompleta al abordar contingencias difíciles de especificar ex ante, pero esenciales para la eficiencia a largo plazo.

Contratación híbrida entre IA y humanos. La IA puede analizar grandes conjuntos de datos y sugerir ajustes contractuales, pero la supervisión humana sigue siendo crucial para evaluar las consecuencias económicas, legales y sociales más amplias. Por ejemplo, la IA puede recomendar modificaciones hipotecarias en función del riesgo de impago, pero los responsables de la toma de decisiones deben sopesar la solvencia del prestamista y la estabilidad macroeconómica. Los responsables políticos deberían promover modelos de gobernanza híbridos donde la IA proporcione información basada en datos, mientras que los agentes humanos conservan la autoridad final para la toma de decisiones.

Transparencia en la contratación de IA. Garantizar la transparencia de la IA es crucial para la confianza y la rendición de cuentas. Los sistemas de IA deben proporcionar documentación clara sobre los factores desencadenantes de la renegociación y los ajustes contractuales, lo que permite a los reguladores evaluar el cumplimiento y resolver disputas. Por ejemplo, si un modelo de IA detecta un préstamo corporativo para su renegociación, debería proporcionar una justificación auditable basada en datos financieros y condiciones del mercado. Los marcos de IA transparentes fomentan la confianza entre las partes contratantes y garantizan la eficacia de la supervisión regulatoria.

Flexibilidad compatible con incentivos. Los contratos basados en IA deben diseñarse para disuadir comportamientos estratégicos, permitiendo al mismo tiempo la flexibilidad necesaria. En el ámbito hipotecario, la IA puede recomendar modificaciones en la amortización para evitar impagos, pero debe proteger contra el oportunismo, como la falsedad de las dificultades financieras por parte de los prestatarios. Al condicionar los ajustes contractuales a criterios verificables, la IA puede mantener la credibilidad contractual y adaptarse a la realidad económica. Garantizar que los contratos basados en IA se ajusten a los principios de compatibilidad de incentivos fortalece la estabilidad financiera y preserva la eficiencia del mercado.

1.5 CONCLUSIONES E IMPLICACIONES POLÍTICAS

La inteligencia artificial está transformando rápidamente el sector financiero y la economía en general, ofreciendo prometedoras vías para mejorar el análisis de datos, la gestión de riesgos y la asignación de capital. La revolución del big data puede generar importantes mejoras en el bienestar de los consumidores de servicios financieros (hogares, empresas y gobiernos). Sin embargo, existen riesgos de que...

Estas ganancias podrían no lograrse plenamente debido a fallas del mercado u operativas. Las fallas del mercado se derivan de fricciones bien conocidas en los mercados financieros (información asimétrica, poder de mercado y externalidades), que la IA puede exacerbar o modificar. A medida que los sistemas de IA se generalizan, plantean nuevos desafíos para los reguladores encargados de equilibrar los beneficios de la innovación con la necesidad de mantener la estabilidad financiera, la integridad del mercado, proteger a los consumidores y garantizar una competencia justa.

Los riesgos asociados con el uso de IA/GenAI son amplios: preocupaciones sobre la privacidad (p. ej., inducir discriminación indeseable), problemas de equidad (p. ej., sesgo algorítmico de los modelos a partir de datos de entrenamiento imperfectos), amenazas a la seguridad (p. ej., facilitar ciberataques o resultados maliciosos), violaciones de la propiedad intelectual (p. ej., infringir materiales legalmente protegidos), falta de explicabilidad (p. ej., incertidumbre sobre cómo se produce una respuesta), problemas de confiabilidad (p. ej., resultados estocásticos que provocan alucinaciones) e impactos ambientales (p. ej., emisiones de CO₂ y consumo de agua). Además, la IA introduce nuevas fuentes de riesgo sistémico. La opacidad y la falta de explicabilidad de los modelos de IA dificultan la anticipación o la comprensión de los riesgos sistémicos hasta que se materializan. Además, el uso de modelos de IA puede aumentar las correlaciones en las predicciones y estrategias, lo que aumenta el riesgo de caídas repentinas, amplificadas por la velocidad, la complejidad y la opacidad del comercio impulsado por IA. Por último, el aumento de los rendimientos a escala en los servicios de IA puede conducir a un mercado concentrado para algunos servicios de IA para intermediarios financieros (es decir, servicios en la nube), lo que aumenta los riesgos sistémicos.

Tres áreas principales de preocupación surgen de los riesgos relacionados con la IA que impactan tres objetivos de política: estabilidad financiera e integridad del mercado; eficiencia y competencia; y privacidad de datos y protección del consumidor. Las compensaciones y tensiones —que pueden representarse como un triángulo de políticas (véase el Capítulo 2)— se configuran según cómo la IA modifica las fallas tradicionales del mercado en los mercados financieros asociadas con la información asimétrica, el poder de mercado y las externalidades. Los responsables políticos deben desarrollar estrategias regulatorias flexibles y robustas. Tres ejemplos ilustran los desafíos para la política.

Sistemas de IA que actúan como agentes. Los sistemas de IA que actúan como agentes autónomos presentan desafíos como la falta de alineación de objetivos, la opacidad y la posibilidad de irregularidades emergentes. Por ejemplo, el uso de agentes con autoaprendizaje en los mercados de valores crea una forma de separación entre propiedad y control: los humanos deciden la estrategia con indicaciones, pero pueden delegar la toma de decisiones al agente de IA. Esto puede inducir una falta de previsibilidad, lo que genera incertidumbre y socava la confianza de los inversores en los mercados financieros. Estos desafíos exigen respuestas regulatorias específicas, incluyendo la responsabilidad basada en resultados (responsabilizar a las empresas por los daños provocados por la IA, independientemente de su intención), la interpretación obligatoria de las decisiones (garantizar que los consumidores puedan impugnar resultados injustos), las pruebas de estrés del sistema y la estandarización de la gobernanza (gobernanza híbrida entre humanos y máquinas). Permitir que modelos de IA opacos dicten el acceso financiero sin rendición de cuentas corre el riesgo de erosionar la confianza pública y exacerbar la exclusión económica.

Nueva asimetría informativa en el uso de la información pública. La IA ha intensificado las disparidades en el procesamiento de datos y el acceso a datos alternativos, lo que exige actualizaciones de los marcos regulatorios tradicionales (p. ej., la Ley Federal de Regulaciones de EE. UU.). Los responsables políticos deberían redefinir la igualdad de acceso estandarizando la divulgación corporativa, promoviendo el uso justo de datos alternativos y abordando el comportamiento algorítmico para evitar distorsiones (p. ej., la colusión algorítmica). Por ejemplo, los responsables políticos deberían esforzarse por limitar el comercio de información que claramente carece de valor social.

Compromiso y flexibilidad en la contratación con IA. Equilibrar el valor del compromiso con la necesidad de flexibilidad en los contratos basados en IA se puede lograr mediante desencadenantes de renegociación predefinidos (p. ej., indicadores macroeconómicos), contratación híbrida entre IA y humanos (p. ej., en hipotecas) y con diseños compatibles con incentivos que disuadan el comportamiento estratégico, permitiendo al mismo tiempo la flexibilidad necesaria.

De cara al futuro, el impacto de la IA en las finanzas dependerá drásticamente de la evolución tecnológica. Existen diferentes escenarios posibles. A corto y medio plazo, el impacto de la IA será más limitado si los copilotos con formación de máster (LLM) complementan, en lugar de reemplazar, las habilidades y los trabajadores humanos del sector financiero. Sin embargo, los efectos serán mayores si los "agentes" de la IA se vuelven cada vez más capaces e independientes, reemplazando potencialmente muchas funciones humanas. En cualquier caso, el enfoque óptimo podría no ser la automatización total, sino un modelo híbrido en el que la IA mejore la toma de decisiones humana al proporcionar información más precisa y oportuna, dejando la decisión final en manos de profesionales con experiencia. Garantizar un uso responsable de la IA, con las debidas garantías de transparencia y gestión de riesgos, será fundamental a medida que las instituciones financieras aumenten su dependencia de GenAI.

Una regulación y una gobernanza eficaces son esenciales para aprovechar los beneficios de la IA y mitigar los riesgos asociados. Los responsables políticos deben equilibrar la innovación con la gestión de riesgos, garantizando la transparencia, la equidad y los estándares éticos. La Ley de IA de la UE, finalizada en 2024, busca proporcionar un marco regulatorio para garantizar una IA segura. Clasifica los sistemas de IA en diversas categorías de riesgo. Estados Unidos y el Reino Unido han adoptado un enfoque menos prescriptivo, basándose más en la autorregulación y en el desarrollo de criterios de seguridad por parte de agencias especializadas. El reto, en particular, para el enfoque de la UE es no frenar la innovación.

Los sistemas financieros impulsados por IA operan transfronterizamente, lo que convierte la fragmentación regulatoria en un riesgo significativo. Las empresas y los operadores pueden aprovecharse de las jurisdicciones más débiles para eludir la gobernanza de la IA, lo que genera arbitraje regulatorio e inestabilidad sistémica. La cooperación internacional es crucial para armonizar la gobernanza de la IA y prevenir dicho arbitraje regulatorio. La estandarización de las reglas de gobernanza de la IA y las metodologías de evaluación de riesgos puede mejorar la colaboración global y abordar desafíos como la privacidad, la seguridad y el acceso equitativo.

Apéndice: Construcción de la Figura 1

La figura 1 se basa en casi todos los artículos (8.015) publicados en las siguientes diez revistas de economía y finanzas entre 2015 y 2024: American Economic Review, Econometrica, Quarterly Journal of Economics, Journal of Political Economy, Review of Economic Studies, Journal of Finance, Journal of Financial Economics, Review of Financial Studies, Review of Finance, Journal of Financial and Quantitative Analysis.

Los artículos que utilizan herramientas de IA y/o estudian los efectos de la IA se identifican utilizando la siguiente lista de palabras clave:

"Inteligencia artificial", "autocodificadores", "reconocimiento automático de voz", "bolsa de palabras", "BERT", "Big Data", "algoritmos de clasificación", "visión artificial", "campo aleatorio condicional", "abundancia de datos", "informatividad de los datos", "ciencia de datos", "DBScan", "árboles de decisión", "aprendizaje profundo", "modelos de difusión", "reducción de dimensionalidad", "red elástica", "aprendizaje de pocos disparos", "GANS", "inteligencia geoespacial", "GPT", "impulso de gradiente", "redes neuronales de grafos", "agrupamiento jerárquico", "procesamiento de imágenes", "tecnología de la información", "k-medias", "agrupamiento k-medias", "modelos de lenguaje", "lasso", "memoria a largo plazo", "LSTM", "aprendizaje automático", "reconocimiento de entidades nombradas", "procesamiento del lenguaje natural", "kit de herramientas de lenguaje natural", "vecino más cercano", "redes neuronales", "red neuronal", "redes neuronales", "PNL", "NLTK", "reconocimiento de patrones", "PCA", "plataforma", "bosque aleatorio", "bosques aleatorios", "aprendizaje por refuerzo", "regresión de cresta", "rnn", "scikitlearn", "aprendizaje autosupervisado", "aprendizaje semisupervisado", "incrustaciones de oraciones", "análisis de sentimientos", "sgd", "agrupamiento espectral", "reconocimiento de voz", "descenso de gradiente estocástico", "aprendizaje supervisado", "máquina de vectores de soporte", "svm", "t-sne", "flujo tensorial", "tensorflow", "análisis de texto", "minería de texto", "tf-idf", "modelado de tópicos", "antorcha", "aprendizaje por transferencia", "modelos de transformadores", "aprendizaje no supervisado", "autocodificadores variacionales", "incrustaciones de palabras", "aprendizaje de disparo cero", "trabajadores de las TIC", "empleados de las TIC", "justicia algorítmica", "robots", "fintech", "automatización"

CAPÍTULO 2

43

Inteligencia artificial y el sector financiero: transformaciones, desafíos y respuestas regulatorias

Con la aparición de grandes modelos lingüísticos, la inteligencia artificial generativa ha cobrado protagonismo en el discurso público. Los LLM han transformado la forma en que las personas interactúan con las computadoras, pasando del código y las interfaces de programación al texto y el habla comunes. La GenAI se distingue por su automatización, rápida adopción y ubicuidad, lo que permite la operación independiente, la toma de decisiones ágil y una amplia integración en hogares y empresas.

Debido a su alta proporción de tareas cognitivamente exigentes, el sector financiero se encuentra entre los más expuestos a la IA. El objetivo de este capítulo es explorar cómo la inteligencia artificial, y especialmente la GenAI, está transformando el sector financiero al mejorar las operaciones, la gestión de riesgos y las interacciones con los consumidores.¹² En primer lugar, se destacan las oportunidades que presenta la GenAI, como la mejora del análisis de datos para el riesgo crediticio y la automatización, al tiempo que se abordan desafíos como los sesgos, las amenazas a la ciberseguridad, la concentración del mercado y los posibles impactos en la estabilidad financiera. A continuación, se ofrece una perspectiva sobre el papel de la IA en la banca central (desde la recopilación de información hasta el análisis macroeconómico) y las implicaciones para la supervisión regulatoria. A pesar de la incertidumbre en el desarrollo futuro de la GenAI, el capítulo describe las compensaciones que enfrentan los responsables de las políticas públicas para equilibrar la innovación con la gestión de riesgos, las preocupaciones sobre la privacidad y las prácticas competitivas en el cambiante panorama financiero. Se analizan los enfoques regulatorios en diferentes jurisdicciones, haciendo hincapié en la necesidad de cooperación internacional para armonizar la gobernanza de la IA y garantizar estándares éticos.

El capítulo se desarrolla de la siguiente manera. La sección 2.1 analiza las novedades de la IA en finanzas y las principales oportunidades para las funciones financieras y la banca central. La sección 2.2 analiza los principales riesgos que la GenAI puede generar en el sector financiero y por qué son diferentes a los del pasado. La sección 2.3 analiza cómo debería regularse la IA en el futuro, comparando diferentes modelos de regulación y destacando la urgente necesidad de coordinación internacional. La sesión final concluye.

¹² Véase también Eisfeldt y Schubert (2024), entre otros.

2.1 IA EN FINANZAS: ¿CUÁLES SON LAS NUEVAS OPORTUNIDADES?

Si bien el entusiasmo en torno a los LLM es nuevo, el uso de IA en el sector financiero no lo es.

La Tabla 1 del Capítulo 1 presenta las oportunidades para el sector financiero derivadas de la evolución de la IA, desde la analítica tradicional hasta el aprendizaje automático y la IA generativa. Nos centramos en las cuatro funciones financieras clave: intermediación financiera, seguros, gestión de activos y pagos.

La analítica tradicional, que se refiere a sistemas expertos basados en reglas, se ha adoptado desde hace tiempo en diversas funciones del sistema financiero. Se ha utilizado para la evaluación de riesgos, el análisis crediticio basado en reglas, la optimización de carteras y la detección de fraudes. Desde la década de 2010, los modelos de aprendizaje automático también se han incorporado a las aplicaciones del sector financiero en una amplia gama de casos de uso, como el análisis de riesgos crediticios y de seguros, la negociación de alta frecuencia (HFR) y las iniciativas contra el blanqueo de capitales y la financiación del terrorismo.¹³

Las instituciones financieras ya utilizan GenAI para optimizar el procesamiento back-end, el asesoramiento robótico, la atención al cliente y el cumplimiento normativo. La mayoría de las aplicaciones son copilotos¹⁴ que complementan, en lugar de reemplazar, las habilidades y los trabajadores humanos. Sin embargo, GenAI también permite la automatización de tareas que hasta hace poco se consideraban exclusivamente humanas, como asesorar a los clientes y persuadirlos para que adquieran productos y servicios financieros. En 2024, el 89 % de las instituciones financieras encuestadas por el Instituto de Finanzas Internacionales utilizaban GenAI en sus operaciones, y el 94 % prevé que el uso de soluciones de IA/ML de terceros aumente a corto plazo.¹⁵

2.1.1 Selección y análisis del riesgo crediticio

La IA podría obtener importantes beneficios en el sector crediticio, ya que la evidencia empírica sugiere que los modelos de IA ofrecen una mayor precisión en la evaluación del riesgo crediticio. Los nuevos modelos de calificación crediticia se diferencian de los tradicionales en dos aspectos fundamentales.¹⁶

La primera es que la tecnología permite a los intermediarios financieros recopilar y utilizar una mayor cantidad de información de datos no estructurados. Las plataformas de crédito fintech pueden utilizar fuentes de datos alternativas, incluyendo información obtenida de la actividad en redes sociales y la huella digital de los usuarios. En el caso de las grandes empresas tecnológicas («big techs») con plataformas existentes, la recopilación de datos se extiende a pedidos, transacciones y reseñas de clientes.¹⁷ Mientras tanto, los modelos de IA son más rápidos en la evaluación del riesgo crediticio, aunque esto no siempre se refleja en un precio más bajo. La evidencia empírica para Estados Unidos muestra que los prestamistas fintech procesan las solicitudes de hipotecas aproximadamente un 20 % más rápido que otros prestamistas, incluso controlando

¹³ Véase Aldasoro et al. (2024d).

¹⁴ Un copiloto LLM se define como una herramienta diseñada para ayudar a los humanos a realizar tareas como el desarrollo de software, Resumen de documentos, redacción de correos electrónicos y generación de imágenes. Esta asistencia se proporciona en respuesta a indicaciones humanas mediante lenguaje natural.

¹⁵ Sobre cómo la IA afecta el asesoramiento al cliente, véase Matz et al. (2024). Los resultados de la encuesta se publican en IIF-EY (2025).

¹⁶ Para una comprensión más profunda de las implicaciones de la IA y la abundancia de datos en los mercados financieros, consulte el Capítulo 3, que analiza el impacto de los datos alternativos y el aprendizaje automático en la dinámica del mercado y la asimetría de la información.

¹⁷ Véase Departamento del Tesoro de Estados Unidos (2016), Jagtiani y Lemieux (2019), Frost et al. (2019) y Berg et al. (2020).

Observables detallados de préstamos, prestatarios y geografía. Al mismo tiempo, una comparación de los precios de los prestamistas en línea (fintech) en el mercado hipotecario estadounidense con los precios de los bancos y la banca paralela (no fintech) muestra que los prestamistas fintech cobran una prima de 14 a 16 puntos básicos sobre las hipotecas bancarias.

45

La segunda diferencia es que, a diferencia de los modelos lineales tradicionales, como el modelo logit, el aprendizaje automático puede capturar estructuras de información no lineales entre variables.¹⁹ Por ejemplo, Gambacorta et al. (2024a) analizan el impacto de un cambio regulatorio en el rendimiento de los modelos de calificación crediticia en China. En noviembre de 2017, el Banco Popular de China emitió un borrador de directrices para regular la banca paralela (marcado por la línea roja discontinua en el panel izquierdo de la Figura 3). Según estas directrices, se prohibió a las instituciones financieras utilizar productos de gestión de activos para invertir en activos crediticios de bancos comerciales o proporcionar servicios de financiación a empresas de tecnología financiera para eludir la regulación. Como resultado de este shock, la oferta de préstamos, especialmente a prestatarios más riesgosos, disminuyó sustancialmente (panel 3A). La tasa de crecimiento del crédito total en la economía china cayó 4 puntos porcentuales en menos de un año después de la introducción de los cambios regulatorios. Además, la repentina congelación de la renovación de líneas de crédito a prestatarios riesgosos provocó que muchas pequeñas y medianas empresas incurrieran en impago.

El Panel 3B muestra la curva ROC²⁰ para tres modelos: (i) un modelo de puntuación fintech (en rojo); (ii) un modelo logit con información tradicional (en azul); y (iii) un modelo logit con toda la información (amarillo).

Antes del shock, el modelo fintech y los modelos logit con información tradicional y no tradicional presentan un comportamiento similar.

Sin embargo, tras el shock regulatorio, el modelo de calificación crediticia fintech presenta un mejor rendimiento que los demás modelos. Una posible explicación podría ser la ventaja relativa de la no linealidad de los modelos de aprendizaje automático (ML) ante cambios en el entorno externo. Los algoritmos de ML parecen adaptarse mejor a la nueva información.


El rendimiento de los modelos de IA no siempre es similar, especialmente cuando existen diferencias en las características institucionales del mercado crediticio específico analizado. Por ejemplo, la Figura 4 compara diferentes estudios y muestra una clara correlación negativa entre las tasas de impago anualizadas (eje x) y los valores de AUROC (eje y) en diferentes estudios de la literatura.

¹⁸ Véase Buchak et al. (2018) y Fuster et al. (2022).

¹⁹ Véase Khandani et al. (2010).

La curva ROC es una representación gráfica que se utiliza para evaluar la capacidad del modelo para distinguir entre morosos y no morosos. Muestra la compensación entre las tasas de verdaderos positivos y las de falsos positivos en diferentes umbrales. El área bajo la curva ROC (AUROC) proporciona una única métrica para resumir el rendimiento del modelo; los valores más altos indican una mejor discriminación entre morosos y no morosos.


FIGURA 3 LAS PUNTUACIONES DE CRÉDITO DE FINTECH MUESTRAN UN MAYOR PODER PREDICTIVO DESPUÉS DE UN CAMBIO EN REGULACIÓN



Notas: La línea discontinua vertical indica cuándo el Banco Popular de China (PBoC) emitió directrices preliminares específicas para endurecer las regulaciones sobre la banca paralela. En particular, desde el 17 de noviembre de 2017, las instituciones financieras no han podido usar productos de gestión de activos para invertir en activos crediticios de bancos comerciales ni proporcionar "servicios de financiación" a otras instituciones (como empresas de tecnología financiera) para eludir las regulaciones. La nueva norma ha tenido un enorme impacto en las fuentes de financiación de las empresas de tecnología financiera. El PBoC también estableció un límite a las tasas de interés cobradas por las empresas de préstamos P2P. Todas las tasas de interés anualizadas, que incluyen las comisiones iniciales cobradas por los préstamos, se limitaron al 36%. Los efectos de estas nuevas normas también se vieron reforzados por las estrictas medidas relativas a los microcréditos en línea que impuso el 1 de diciembre de 2017 la Oficina del Equipo de Liderazgo del Trabajo de Rectificación Especial de Riesgo Financiero de Internet de China. 1 El eje vertical informa el área bajo la curva ROC (AUROC) para cada modelo. El AUROC es una métrica ampliamente utilizada para juzgar el poder discriminatorio de las puntuaciones crediticias. El AUROC varía entre el 50% (predicción puramente aleatoria) y el 100% (predicción perfecta).

Fuente: Gambacorta et al. (2024a).

FIGURA 4 COMPARABILIDAD DEL ÁREA BAJO LA CURVA ROC: ESTUDIOS SELECCIONADOS



Notas: Los valores de AUROC que se muestran en el eje vertical se extraen de la Tabla A2 de Berg et al. (2020). Los resultados no se encuentran en los artículos originales, pero fueron proporcionados por los autores utilizando el mismo conjunto de datos del artículo. El eje horizontal muestra las tasas de impago.

Fuente: Berg et al. (2020); Gambacorta et al. (2024a).

Pero la IA no es la única explicación de las menores tasas de impago. Para las empresas del ecosistema de las grandes tecnológicas, el impago es estratégicamente más difícil, ya que pueden aprovechar las cuentas por cobrar de estas empresas para liquidar sus deudas. Además, debido a los efectos de red y los altos costos de cambio, las grandes tecnológicas pueden exigir el pago de préstamos simplemente amenazando con una degradación o la exclusión de su ecosistema en caso de impago.

Curiosamente, el crédito a las grandes tecnológicas presenta tasas de impago más bajas que el crédito bancario. La Tabla 2 compara los préstamos morosos (NPL) de los bancos chinos y de MYbank, centrándose en el crédito a las pequeñas y medianas empresas (pymes). Como se indica en las dos primeras filas de la tabla, en promedio, los NPL del sector bancario chino fueron sustancialmente mayores que los de MYbank en el período 2017-2023, incluso durante la pandemia de COVID-19 (2020).

47

CUADRO 2 CALIDAD DEL CRÉDITO Y TASAS DE INTERÉS

Calidad crediticia de las PYMES: ratio de morosidad			Tipos de interés medios PYMES	
Año	Bancos1	Mi banco	Bancos1	MYbank2
2017	5,85%	1,23%	6,55%	17,70%
2018	5,50%	1,30%	6,16%	13,39%
2019	3,22%	1,30%	6,70%	10,21%
2020	2,99%3	1,52%	5,88%4	9,03%
2021	-	1,53%	5,69%	9,23%
2022	2,18%5	1,94%	5,25%	7,74%
2023	-	2,28%	4,78%	8,24%

Nota: Los préstamos en mora indican préstamos que generalmente están vencidos a partir de 90 días. Véase "Medidas provisionales para la clasificación de riesgos de los activos financieros de los bancos comerciales". (1) Líneas de crédito inferiores a 10 millones de yuanes (5 millones en 2017 y 2018). (2) Datos obtenidos de la información del balance público dividiendo los intereses devengados y el total de préstamos a las PYMES. (3) A agosto de 2020. (4) Enero a noviembre de 2020. (5) A abril de 2022.

Fuente: CBIRC; Informes Anuales de MYbank; De Fiore et al. (2024)

Curiosamente, el hallazgo sobre las medidas ex post del riesgo crediticio no se refleja en las tasas de interés, que son sustancialmente más altas (en promedio) para el crédito a las grandes tecnológicas. Tres factores pueden causar que las tasas de interés para el crédito a las grandes tecnológicas sean más altas que las del crédito bancario. En primer lugar, los costos de financiamiento de MYbank son sustancialmente más altos que los de los bancos tradicionales. Esto refleja la capacidad limitada de las grandes tecnológicas para aceptar depósitos minoristas. Las grandes tecnológicas podrían establecer un banco en línea, pero las autoridades reguladoras suelen restringir la apertura de cuentas bancarias remotas (en línea). En China, por ejemplo, los dos grandes bancos tecnológicos (MYbank y WeBank) dependen principalmente de la financiación del mercado interbancario y de los certificados de depósito, que suelen ser más costosos que los depósitos minoristas.²³ En segundo lugar, las empresas que obtienen préstamos de MYbank suelen ser más pequeñas que los clientes de los bancos tradicionales, por lo que el riesgo potencial ex ante para MYbank también es mayor que el de los bancos tradicionales. En tercer lugar, el procesamiento de datos para la calificación crediticia podría tener altos costos fijos para establecer la infraestructura de TI necesaria y crear un equipo altamente especializado. Estos costos pueden ser particularmente altos al principio, cuando el número de prestatarios es bajo, y luego disminuir con el tiempo a medida que aumenta la

transacciones.

21 MYbank es un banco chino exclusivamente online fundado por Ant Group en 2015. Proporciona principalmente microcréditos a pymes utilizando modelos propios de calificación crediticia basados en big data e inteligencia artificial, en lugar de evaluaciones tradicionales basadas en garantías.

22 Estos resultados son consistentes con Huang et al. (2020), quienes encuentran que la calificación crediticia de las grandes tecnológicas permite una mejor predicción de los incumplimientos de préstamos durante épocas normales y períodos de grandes shocks exógenos, lo que refleja ventajas de información y modelado.

23 Véase BIS (2019).

Esto se refleja en el diferencial entre los tipos de interés del crédito a las grandes tecnológicas y los del crédito bancario, que rondaba el 11,2% en 2017, cuando MYbank empezó a ofrecer crédito a los comerciantes con códigos de respuesta rápida (QR), y solo el 3,5% a finales de 2023.

48

2.1.2 Seguimiento y garantías

Además de evaluar el riesgo crediticio, los prestamistas incurren en costos para supervisar a los prestatarios y exigir el cumplimiento de los pagos de los préstamos. Tradicionalmente, los bancos suelen exigir activos tangibles (como bienes inmuebles) como garantía a los prestatarios para abordar los problemas de cumplimiento.²⁴ Estos activos se utilizan para aumentar las tasas de recuperación en caso de impago del préstamo. Los bancos también dedican tiempo y recursos a supervisar los proyectos de sus clientes para limitar el riesgo de que los prestatarios los implementen de forma diferente a lo acordado inicialmente. Mediante este proceso, pueden forjar relaciones a largo plazo con los prestatarios.

Los modelos de IA podrían ayudar a supervisar el reembolso de préstamos de forma más eficiente que los bancos. Por ejemplo, las grandes tecnológicas pueden garantizar el reembolso de créditos amenazando con excluir a empresas de su ecosistema o deduciendo los pagos de sus ingresos si ofrecen una plataforma de comercio electrónico en la que operan. Además, a diferencia de los bancos, las grandes tecnológicas no necesitan necesariamente garantías para conceder préstamos; pueden abordar los problemas derivados de la información asimétrica utilizando datos no tradicionales de sus negocios, a los que los bancos no tienen acceso.


Gambacorta et al. (2023) demuestran que, efectivamente, los datos sustituyen las garantías en China. A partir de una muestra aleatoria de más de dos millones de empresas chinas que han recibido crédito de Ant Group y de la banca tradicional, los autores analizan cómo el crédito otorgado a estas empresas (crédito a grandes tecnológicas, crédito bancario con garantía o crédito bancario sin garantía) reacciona a los cambios en el volumen de transacciones de cada empresa y al clima macroeconómico general (medido por los precios de la vivienda).

Descubrieron que el crédito proporcionado por las grandes empresas tecnológicas no está correlacionado con las condiciones económicas locales o los precios de las viviendas, sino que responde fuertemente a los volúmenes de transacciones y a la calificación crediticia de una empresa.

Por otro lado, el crédito otorgado por los bancos (con y sin garantía) está significativamente correlacionado con las condiciones económicas locales. Estos hallazgos se resumen en la Figura 5.

Dado que las grandes tecnológicas no necesitan garantías (como una vivienda) para exigir el pago, su crédito no responde significativamente al ciclo inmobiliario. Esto puede alterar el mecanismo de transmisión de la política monetaria: el canal de garantías se debilita, mientras que el crédito de las grandes tecnológicas reacciona más a las perturbaciones idiosincrásicas de las empresas.

FIGURA 5 DATOS VERSUS COLATERAL: EL CRÉDITO DE LAS GRANDES TECNOLÓGICAS REACCIONA MENOS A LOS CAMBIOS EN LA SOCIEDAD PRECIOS Y MÁS SEGÚN CARACTERÍSTICAS ESPECÍFICAS DE LA EMPRESA



Notas: Elasticidad del crédito con respecto a los precios de la vivienda y el PIB. La figura presenta el coeficiente de tres regresiones diferentes (una para cada tipo de crédito) en las que el logaritmo del crédito se regresa con respecto al logaritmo de los precios de la vivienda a nivel de ciudad, el logaritmo del PIB a nivel de ciudad y un conjunto completo de variables ficticias de tiempo. Nivel de significancia: **P < 0,05; ***P < 0,01.

Fuente: Gambacorta et al. (2024a).


Incluso las pequeñas empresas del sector informal pueden ser evaluadas mediante el uso de datos de Servicios auxiliares (como pagos). En China, Ant Group ofrece servicios de pago mediante códigos QR y acceso a servicios de pago digital para comercios tradicionales. Luego, utiliza la información del historial de pagos de los comerciantes para otorgarles crédito (o no). El uso de códigos QR para pagos en China permite a estos comerciantes acceder no solo al crédito del propio Grupo Ant, sino también a crédito bancario sin garantía.

La Figura 6 muestra la probabilidad de que una empresa que utiliza pagos con código QR reciba crédito. El eje x representa el número de meses desde que la empresa comenzó a utilizar pagos con código QR; el eje y representa la probabilidad de que una empresa tenga acceso a crédito de las grandes tecnológicas. Cuanto más tiempo lleve una empresa utilizando pagos con código QR, mayor será la probabilidad de acceder a crédito de grandes tecnológicas. Por ejemplo, un año después de empezar a usar pagos con código QR, la probabilidad de acceder a una línea de crédito de grandes tecnológicas es de casi el 60 %. Esta probabilidad aumenta al 80 % tras dos años y al 87 % tras tres años.

Para las pymes con exclusión financiera, obtener crédito de prestamistas alternativos que utilizan técnicas de IA puede allanar el camino hacia la financiación convencional. La transición hacia los préstamos bancarios es importante, ya que muchos préstamos de las grandes tecnológicas y fintech son pequeños y con vencimientos cortos.²⁵ A medida que las PYME realizan transacciones y toman préstamos de las grandes empresas tecnológicas y fintech, construyen un historial financiero en el registro de crédito que puede ayudar a los bancos tradicionales a evaluarlas y, eventualmente, otorgarles crédito.²⁶

El crédito a las grandes tecnológicas suele concederse por periodos cortos, de seis meses a un año. Además, suele reembolsarse bien en... Anticipación de la fecha de vencimiento (Liu et al., 2022). En el caso de las fintech, la evidencia de Brasil, Francia e India sugiere que los prestatarios son más pequeños y tienen mayor apalancamiento, y que los préstamos tienen un vencimiento más corto y una tasa de interés más alta que el préstamo bancario promedio para pymes (Beaumont et al., 2024; Ghosh et al., 2024; Ornelas y Pecora, 2022). El acceso financiero de las pymes también puede mejorar a medida que las instituciones financieras reorganizan sus líneas de negocio. En Perú, por ejemplo, las microfinanzas, inicialmente centradas en la agricultura, se han diversificado hacia préstamos a micro y pequeñas empresas (Armas et al., 2024).

FIGURA 6 EL USO DE CÓDIGOS QR EN PAGOS PERMITE A LAS EMPRESAS ACCEDER AL CRÉDITO DE LAS GRANDES TECNOLÓGICAS (%)




Notas: Las líneas discontinuas indican los percentiles 5 y 95. El eje x indica la duración del código QR, es decir, el número de meses desde que la empresa comenzó a utilizar el sistema de pago con código QR. El eje y indica la probabilidad de que una empresa acceda al crédito de las grandes tecnológicas.

Fuente: Beck et al. (2022).

Beck et al. (2022) muestran que las empresas que recurren a préstamos de las grandes tecnológicas dejan una huella en el registro de crédito, lo que aumenta notablemente su probabilidad de obtener una línea de crédito bancaria. Sin embargo, la Figura 7 muestra que existen diferencias sustanciales entre los efectos del simple acceso al crédito de las grandes tecnológicas y los efectos del uso real del crédito. Controlando los efectos de la demanda, cuando las empresas tienen acceso al crédito de las grandes tecnológicas pero no lo utilizan, los efectos indirectos sobre el crédito bancario son bastante limitados. Esto se debe a que el simple acceso al crédito de las grandes tecnológicas no es visible en el registro de crédito para los bancos. Tras tres años de uso de códigos QR, la probabilidad de utilizar crédito bancario para las empresas con acceso a crédito MYbank es de tan solo el 3% (Figura 7A). Por el contrario, el uso real de una línea de crédito de las grandes tecnológicas aumenta significativamente la probabilidad de acceder a crédito bancario, probablemente porque en este caso se crea una huella financiera en el registro de crédito. Tres años después de empezar a utilizar códigos QR, la probabilidad de utilizar una línea de crédito bancaria ronda el 17% (Figura 7B).

Esto sugiere que la inclusión de las exposiciones crediticias de las grandes empresas tecnológicas en el registro de crédito actúa como un dispositivo de señalización y permite que los bancos identifiquen y evalúen mejor a las PYME.

FIGURA 7 EFECTO DE DERRAME DEL CRÉDITO DE LAS GRANDES TECNOLÓGICAS AL CRÉDITO BANCARIO (%)



Notas: Las líneas discontinuas indican los percentiles 5 y 95. El eje x indica la duración del código QR y el número de meses desde que la empresa comenzó a utilizar el sistema de pago con código QR. El eje y indica la probabilidad de que una empresa utilice crédito bancario.

Fuente: Beck et al. (2022).

Pero el crédito proporcionado mediante técnicas de IA también podría aumentar el riesgo crediticio en algunos casos. En Alemania, por ejemplo, los prestamistas en línea sustituyen los préstamos bancarios por préstamos al consumo de alto riesgo. En los mercados de crédito al consumo estadounidenses, los préstamos en línea sustituyen los préstamos bancarios entre los prestatarios marginales, a la vez que los complementan para préstamos pequeños.

Sin embargo, es interesante observar que el desempeño de los prestamistas en línea parece depender de la cantidad y calidad de la información disponible para ellos.²⁷

51

Los bancos también pueden asociarse con grandes empresas tecnológicas y fintechs, donde las firmas con conocimientos tecnológicos proporcionan capacidades de calificación crediticia, mientras que los bancos proporcionan la financiación necesaria. Al mismo tiempo, los propios bancos están ampliando el uso de análisis avanzados para la concesión de crédito, ya que las innovaciones digitales les han abaratado la recopilación y el procesamiento de datos. Un área prometedora es la financiación del comercio, donde las pymes parecen especialmente limitadas y las aplicaciones digitales pueden emplear información en tiempo real sobre los envíos.²⁸ Una pregunta que aún queda por responder es si las fintechs y las grandes empresas tecnológicas finalmente se aventurarán en la concesión de préstamos de mayor cuantía y con mayor vencimiento, de forma similar a la de los bancos.

La IA también altera el efecto de los préstamos relacionales, ya que la adopción del aprendizaje automático en la calificación crediticia reduce la importancia de la información blanda obtenida a través de una relación duradera con los clientes. Durante una relación crediticia con una empresa, la aplicación de técnicas de IA para la selección y supervisión de capacidades mitiga la extracción de rentas de los préstamos relacionales en tiempos normales, pero no proporciona protección adicional sobre las cantidades y los tipos de interés para los prestatarios con relaciones más largas durante una crisis. En otras palabras, los efectos de los préstamos relacionales sobre los volúmenes y precios del crédito, que son perjudiciales en tiempos normales pero beneficiosos durante las crisis, se suavizan mediante el uso de técnicas de IA para la calificación crediticia. Por lo tanto, si bien los préstamos de bancos sin IA a empresas relacionales son anticíclicos, los préstamos con IA a empresas relacionales no parecen verse influenciados por las perturbaciones macroeconómicas generales, sino que son más reactivos a las condiciones específicas de cada empresa.²⁹

Al mejorar la calificación crediticia y el acceso de las pymes al crédito, la tecnología digital puede tener efectos en la economía real. La aplicación de la IA para la calificación crediticia puede impulsar el crecimiento y el empleo de las pymes. En cuanto a los efectos reales del crédito a las grandes tecnológicas, las empresas chinas con préstamos a estas grandes empresas han experimentado, en general, una mayor actividad comercial que sus contrapartes con exclusión financiera. Con efectos que podrían variar a lo largo del ciclo. Beck et al. (2022) utilizan tres pruebas diferentes para verificar si el acceso al crédito de las grandes tecnológicas produce efectos reales en la actividad de las empresas. La primera prueba analiza el período pre-COVID de 2017 a 2019; la segunda considera únicamente el shock exógeno generado por la introducción de un producto de préstamo para grandes tecnológicas en agosto de 2017; y la tercera prueba compara el período pre-pandemia con el período pandémico, considerando empresas con y sin acceso al crédito de las grandes tecnológicas. La Figura 8 presenta los resultados.

²⁷ Para el caso de Alemania, véase De Roure et al. (2016); para los Estados Unidos, véase Tang (2019).

²⁸ Véase Ahnert et al. (2024) para el uso de análisis avanzados por parte de los bancos, y BIS (2023) para aplicaciones digitales en el comercio financiero.

²⁹ Véase Gambacorta et al. (2025) para un estudio sobre el impacto de la adopción de IA en la calificación crediticia en los préstamos relacionales por parte de los italianos bancos.

³⁰ Véase Hau et al. (2024).

52

De las tres pruebas diferentes. En el período prepandémico, el volumen de transacciones después de tres meses aumentó aproximadamente un 3,5 % más para las empresas que tenían acceso al crédito de las grandes tecnológicas (grupo tratado) en comparación con aquellas con características similares que no tenían acceso (grupo de control). Cuando los autores limitan su análisis al momento del lanzamiento del producto crediticio, los efectos son más considerables: el volumen de transacciones después de tres meses aumenta un 9,6 % más para las empresas que recibieron una oferta inicial de un préstamo de las grandes tecnológicas que para las demás. Finalmente, la tercera prueba muestra que el efecto real durante la pandemia de COVID-19 fue significativamente mayor que en el período prepandémico: el crecimiento del volumen de transacciones es un 20 % mayor para las empresas con acceso al crédito de las grandes tecnológicas que para las que estaban excluidas financieramente.

FIGURA 8 EFECTOS REALES DEL ACCESO AL CRÉDITO DE LAS GRANDES TECNOLÓGICAS

Aumento del volumen de transacciones (registro)



Notas: La primera prueba (histograma izquierdo) evalúa los efectos (tras tres meses) de la concesión de crédito a las grandes tecnológicas sobre el volumen de transacciones de las empresas durante el período 2017-2019. El análisis se basa en un emparejamiento por puntuación de propensión combinado con un análisis de diferencias en diferencias. La segunda prueba (histograma central) utiliza un enfoque similar, pero se centra únicamente en la oferta inicial de préstamos a las grandes tecnológicas. Ant Group introdujo la posibilidad de los productos de crédito MYbank a los comercios con código QR a finales de junio de 2017 y comenzó a ofrecer préstamos en agosto de 2017. La tercera prueba (histograma derecho) considera los efectos específicos durante la pandemia.

Fuente: Beck et al. (2022).

Los cambios sectoriales en el crédito debidos a cambios en la calificación crediticia también podrían generar beneficios en términos de crecimiento. En particular, una menor ponderación de los activos físicos como garantía, inducida por una mayor aplicación de la IA, podría ayudar a financiar proyectos productivos en sectores donde el capital tangible es más escaso. La evidencia empírica sugiere que las empresas con garantía inmobiliaria tienden a ser menos productivas, y una mayor proporción de crédito asignado al sector inmobiliario, con su garantía fácilmente disponible, se ha asociado con un menor crecimiento de la productividad agregada, tanto en las economías de mercados emergentes como a lo largo del tiempo. Un mayor uso de datos en las decisiones crediticias podría mejorar la asignación de capital entre sectores e impulsar el crecimiento de la productividad, aunque estos efectos podrían materializarse lentamente con el tiempo.

31 Véase Doerr (2020) para obtener evidencia sobre empresas con garantías inmobiliarias y Müller y Verner (2024) para el impacto del crédito. Asignación al sector inmobiliario sobre el crecimiento de la productividad agregada.

2.1.3 IA para la banca central

Los bancos centrales no son meros observadores pasivos en la monitorización del impacto de la IA en la economía y el sistema financiero. Pueden aprovechar las herramientas de IA para alcanzar sus objetivos de política y abordar los desafíos emergentes. En particular, el uso de LLM e IA puede respaldar las tareas clave de los bancos centrales: (i) recopilación de información y compilación estadística, (ii) análisis macroeconómico y financiero para respaldar la política monetaria, (iii) supervisión de los sistemas de pago, y (iv) supervisión y estabilidad financiera. Esta sección presenta ejemplos relevantes en cada área. En la Tabla 3.32 se presenta una lista seleccionada de proyectos en curso en los bancos centrales.

53

Recopilación de información y compilación estadística

Los bancos centrales se enfrentan a desafíos para garantizar datos de alta calidad para el análisis económico debido a problemas como la limpieza de datos y el aumento de la complejidad de los datos.³³ Cada vez más, utilizan técnicas de aprendizaje automático (ML), como los bosques de aislamiento, para detectar valores atípicos en conjuntos de datos grandes y granulares. Los bosques de aislamiento son escalables y eficaces, pero tradicionalmente se limitan a datos numéricos; los bancos centrales, incluido el Banco de Israel y el BCE, han innovado para incluir variables categóricas convirtiéndolas en forma numérica. Colaboraciones como la entre el Deutsche Bundesbank e investigadores de IA utilizan un enfoque de dos pasos (detección automatizada seguida de revisión por expertos) para mejorar la eficacia y la explicabilidad de los algoritmos, al tiempo que equilibran los costes de la intervención humana.

Análisis macroeconómico y financiero para apoyar la política monetaria

Los bancos centrales se enfrentan a retos a la hora de extraer información de diversas fuentes de datos para el análisis macroeconómico. El aprendizaje automático ofrece herramientas valiosas para optimizar este proceso.³⁴ El Banco de Inglaterra utiliza redes neuronales para descomponer la inflación de servicios en sus componentes, capturando no linealidades complejas y utilizando datos granulares. El Banco de Corea combina redes neuronales con modelos tradicionales para mejorar la previsión inmediata, especialmente durante períodos volátiles como la pandemia de COVID-19. El Banco de Francia emplea bosques aleatorios en datos de Twitter para medir las expectativas de inflación en tiempo real, con una buena correlación con las métricas tradicionales. El Banco de Indonesia utiliza aprendizaje automático con datos de texto para evaluar la credibilidad de las políticas, vinculando una mayor credibilidad con expectativas de inflación mejor ancladas. La Reserva Federal utiliza FinBERT, un modelo de lenguaje perfeccionado, para generar índices de sentimiento a partir del Libro Beige, lo que facilita la previsión inmediata del PIB y la predicción de recesiones. La adaptación de los modelos de lenguaje a la terminología de la banca central mejora la precisión en la interpretación de las comunicaciones de la banca central y la predicción de las reacciones del mercado.

32 Para un análisis del uso de la IA en la banca central, véase Araujo et al. (2024). Para más información sobre los ejemplos seleccionados, así como una lista más amplia de casos de uso, consulte Araujo et al. (2022, 2023). Véase también Beerman et al. (2021) para más casos de uso sobre supervisión.

Los casos de uso relacionados con la recopilación de información se describen con mayor detalle en Kamenetsky Yadan (2021), Accornero y Boscaroli (2021) y Cagala et al. (2021). En particular, Gray y Jones (2025) describen el caso del Banco de la Reserva de Australia, que utiliza aplicaciones de IA para facilitar el procesamiento de encuestas.

34 Los casos de uso de la política monetaria se describen en Buckmann et al. (2023), Yi et al. (2022), Denes et al. (2021), Abdul Jabbar et al. (2022), Du et al. (2024), y Gambacorta et al. (2024b).

[illegible]

Supervisión de los sistemas de pago

El buen funcionamiento de los sistemas de pago es vital para la estabilidad financiera, pero la gran cantidad de datos transaccionales dificulta la detección de anomalías.³⁵ Los modelos de aprendizaje automático (ML), como las redes neuronales y los autocodificadores, identifican eficazmente transacciones anómalas, incluyendo posibles casos de lavado de dinero. El Proyecto Aurora del Centro de Innovación del BPI demuestra que las redes neuronales de grafos superan a los métodos tradicionales basados en reglas, especialmente con datos agrupados que mantienen la confidencialidad. Los bancos centrales de Canadá, los Países Bajos y Ecuador han utilizado con éxito autocodificadores para detectar anomalías como retiradas masivas de fondos y perturbaciones operativas.

55

Supervisión y estabilidad financiera

Los supervisores necesitan analizar una amplia gama de fuentes de datos para supervisar eficientemente a las instituciones financieras. A menudo, estas fuentes son documentos de texto como artículos periodísticos, documentos bancarios internos o evaluaciones supervisoras.³⁶ Filtrar esta gran cantidad de información para extraer información relevante puede requerir mucho tiempo, y con el volumen de datos en constante crecimiento, se vuelve prácticamente insuperable. Además, los análisis relacionados con los riesgos climáticos y cibernéticos se han convertido en prioridades de supervisión, pero carecen de la infraestructura de datos integral ya existente para los riesgos tradicionales.³⁷ Herramientas de IA como Athena del BCE y LEX de la Reserva Federal utilizan modelos de lenguaje y técnicas de PLN para clasificar documentos, realizar análisis de sentimiento e identificar riesgos, lo que reduce significativamente el tiempo de análisis. El Banco Central de Malasia emplea IA para garantizar una comunicación supervisora coherente. El sistema ADAM del Banco Central de Brasil utiliza modelos de aprendizaje automático para identificar rápidamente a los prestatarios con provisiones insuficientes.³⁸

2.2 IA EN FINANZAS: VIEJOS PROBLEMAS, NUEVOS DESAFÍOS

A medida que se han ampliado las oportunidades que ofrece la IA, también lo han hecho los desafíos (véase la Tabla 1 del Capítulo 1). El uso generalizado de la IA en el sector financiero puede exacerbar las amenazas a la privacidad del consumidor y la ciberseguridad. Además, la mayoría de los modelos de IA tienen una naturaleza inherentemente de "caja negra" y sus predicciones son difíciles de explicar. Además, pueden propagar sesgos en los datos con los que se entrenan.

35 Los casos de uso relacionados con la supervisión de los sistemas de pago se describen con más detalle en BIS Innovation Hub (2023), Sabetti y Heijmans (2020), y Rubio et al. (2021).

El Bundesbank utiliza una versión interna de GPT-4o para gestionar información privada y confidencial (Blankenburg y Röhe, 2024). El Banco de Tailandia ha realizado un análisis exhaustivo de las aplicaciones de los copilotos, que abarcan desde el resumen de documentos hasta la recuperación de información relevante, destacando las limitaciones en el cambio de idioma (Yampratoom, 2024). El uso de un copiloto de Generación Aumentada de Recuperación (RAG) en la Junta de la Reserva Federal para responder preguntas específicas basadas en documentos financieros de bancos comerciales indica respuestas de buena calidad para preguntas sencillas y la necesidad de supervisión humana para preguntas más complejas (Botti et al., 2025).

37 Se puede encontrar más información sobre los casos de uso de supervisión en ECB (2023), Du et al. (2024), Tan et al. (2021) y Beerman y otros (2021).

38 Mientras los bancos centrales y las instituciones financieras están integrando "copilotos de IA" en sus operaciones diarias, La transición hacia flujos de trabajo intensivos en IA requiere abordar varios desafíos de capital humano. Estos incluyen la capacitación y el perfeccionamiento del personal existente, la atracción de nuevos talentos y el fomento de una cultura que promueva la innovación (Bell et al., 2025).


2.2.1 Sesgo y discriminación, riesgos legales y ciberseguridad

El uso de IA plantea problemas de sesgo y discriminación. Tres ejemplos destacan. El primero se relaciona con la protección del consumidor y las prácticas crediticias justas. Al igual que con los modelos tradicionales, los modelos de IA pueden reflejar sesgos e imprecisiones en los datos con los que se entrenan, lo que plantea riesgos de decisiones injustas, excluye a ciertos grupos de los mercados de seguros socialmente deseables y perpetúa las disparidades en el acceso al crédito mediante la discriminación algorítmica.³⁹

Por ejemplo, hay evidencia de modelos de calificación crediticia basados en aprendizaje automático que, en el mercado hipotecario de EE. UU., los prestatarios negros e hispanos tienen menos probabilidades de beneficiarse de tasas de interés más bajas que los prestatarios de otras comunidades.⁴⁰ Los consumidores se preocupan por estas

Riesgos: La evidencia reciente de una encuesta representativa de hogares estadounidenses sugiere un menor nivel de confianza en la GenAI que en los servicios gestionados por personas, especialmente en áreas de gran importancia como la banca y las políticas públicas (Figura 9A) y cuando las herramientas de IA son proporcionadas por grandes tecnológicas. Las diferencias entre los grupos demográficos son pequeñas, con la excepción de que las mujeres declaran una confianza significativamente menor en las herramientas de GenAI (Figura 9B). Este patrón concuerda con su menor uso y conocimiento de la GenAI y podría estar relacionado con las preocupaciones sobre la seguridad y la privacidad al tratar con empresas en línea.⁴¹

FIGURA 9 EN GenAI NO CONFIAMOS



Notas: El panel izquierdo muestra las respuestas promedio a la siguiente pregunta: "¿En las siguientes áreas, confiaría menos o más en las herramientas de inteligencia artificial (IA) que en los servicios tradicionales operados por humanos? Indique su nivel de confianza en una escala del 1 (mucha menos confianza que en un humano) al 7 (mucha más confianza)". El panel central muestra los niveles promedio de confianza para las respectivas preguntas por grupo de hogares. El panel derecho muestra las puntuaciones promedio a la pregunta: "¿Cuánto confía en que las siguientes entidades almacenen de forma segura sus datos personales cuando utilizan herramientas de inteligencia artificial? Indique su nivel de confianza en una escala del 1 (ninguna confianza en la capacidad de almacenar de forma segura datos personales) al 7 (confianza total)".

Fuente: Aldasoro et al. (2024a); Encuesta de expectativas de los consumidores del Banco de la Reserva Federal de Nueva York; cálculos de los autores.

Para una exploración detallada de cómo la IA puede desalinearse con las intenciones humanas y los desafíos de gobernanza que plantea, consulte el Capítulo 4, que analiza la naturaleza de "caja negra" de la IA y las complejidades de la intención y la rendición de cuentas.

40 Véase Fuster et al. (2019).

41 Véase Armantier et al. (2021).

El segundo ejemplo se relaciona con el desafío de garantizar la privacidad y confidencialidad de los datos al gestionar volúmenes crecientes, otra preocupación clave para los usuarios. Dados los altos estándares de privacidad que deben cumplir las instituciones financieras, esto aumenta los riesgos legales. La falta de explicabilidad de los modelos de IA (es decir, su naturaleza de "caja negra"), así como su tendencia a la "alucinación", amplifican estos riesgos. Existen marcadas diferencias en la confianza que los hogares depositan en cómo las herramientas de IA almacenan sus datos personales, según las instituciones que las proporcionan. Los encuestados manifiestan la mayor confianza en las instituciones financieras tradicionales para el almacenamiento seguro de datos como su historial de transacciones bancarias, geolocalización o datos de redes sociales (Figura 9C).

57

El tercer ejemplo es el problema de las alucinaciones. Los LLM pueden presentar una respuesta factualmente incorrecta como si fuera correcta, e incluso inventar fuentes secundarias para respaldar sus afirmaciones falsas. Desafortunadamente, las alucinaciones son una característica, no un defecto, de estos modelos.

Por ejemplo, los LLM alucinan porque están entrenados para predecir la palabra estadísticamente plausible basándose en cierta información. Pero, en muchos casos, no pueden distinguir entre lo lingüísticamente probable y lo factualmente correcto. Además, existe el problema de "basura entra, basura sale": la calidad del resultado depende de la calidad de los datos de entrada.

Por lo tanto, datos inexactos o irrelevantes podrían producir resultados inexactos o irrelevantes. Esto requiere intervención humana en áreas sensibles.

La dependencia de la IA también aumenta la preocupación por los ciberataques en el sector financiero, ya que la GenAI permite a los hackers crear correos electrónicos de phishing y malware convincentes, imitar a personas y crear avatares falsos, lo que aumenta el riesgo de fraude. La IA también introduce nuevas ciberamenazas, como los ataques de inyección rápida, en los que las entradas provocan un comportamiento no deseado del modelo (p. ej., el «jailbreak de la abuela»).

⁴² Los ataques de envenenamiento de datos y de modelos implican la manipulación de los datos o procesos de entrenamiento de la IA para comprometer su integridad. A medida que los datos generados por IA se vuelven más frecuentes, estos ataques podrían tener graves consecuencias, aumentando los riesgos operativos para las instituciones financieras.

⁴³ Sin embargo, al igual que la IA aumenta los riesgos cibernéticos, también puede ser utilizada por los ciberdefensores en su análisis de amenazas y la monitorización de redes informáticas. En una encuesta reciente del BPI realizada entre los miembros del Grupo Global de Ciberresiliencia, un grupo de expertos en ciberseguridad de bancos centrales, la mayoría de los bancos centrales informaron que el uso de modelos GenAI para la ciberseguridad puede ser muy eficaz.

⁴⁴

La "fuga de la abuela" es un truco en el que alguien le pide a una IA que finja estar contando una historia (como si leyera un cuento de una abuela antes de dormir) para introducir solicitudes dañinas o restringidas que la IA normalmente rechazaría. Al disfrazar la solicitud como parte de un juego de rol inofensivo, la persona a veces puede eludir las reglas de seguridad de la IA.


⁴³ Además de los riesgos cibernéticos, la GenAI podría aumentar los riesgos operativos en las instituciones financieras a través de una toma de decisiones sesgada, problemas de calidad de los datos, falta de transparencia, incumplimiento normativo y dependencia excesiva de la automatización, lo que podría generar interrupciones, daños a la reputación y preocupaciones éticas si no se rige y monitorea adecuadamente (véase BIS, 2024).

⁴⁴ Aldasoro y otros (2024b).

2.2.2 Concentración del mercado en el ecosistema de IA

El rápido avance de la IA depende de una cadena de suministro cada vez más compleja, con múltiples capas de tecnología que trabajan juntas para impulsar las aplicaciones de IA. La cadena de suministro de IA consta de cinco capas de entrada clave: hardware, infraestructura en la nube, datos de entrenamiento, modelos de base y aplicaciones de IA (véase la Figura 10). Cada capa está sujeta a las fuerzas del mercado que configuran su estructura, lo que a menudo resulta en altos niveles de concentración.

FIGURA 10 LA CADENA DE SUMINISTRO DE IA



Fuente: Gambacorta y Shreefi (2025).

La capa de hardware es fundamental para las aplicaciones de IA, en particular para los microprocesadores como las GPU, que son esenciales para el entrenamiento y la inferencia de modelos de IA. Nvidia domina este mercado, con una cuota de mercado informada que supera el 90 % (Figura 11A).⁴⁵ Las GPU de Nvidia se incluyen en CUDA, una plataforma de computación paralela que se ha convertido en el estándar de la industria. Esta integración, junto con adquisiciones estratégicas como Mellanox, ha consolidado el liderazgo de mercado de Nvidia. A pesar de la competencia de Advanced Micro Devices (AMD), Intel y grandes empresas tecnológicas como Microsoft, Google y Amazon, la ventaja de ser pionera de Nvidia y la dificultad para migrar de CUDA crean importantes barreras de entrada para otras empresas. Sin embargo, empresas chinas como Alibaba, Baidu y Huawei también están empezando a producir sus propios microprocesadores, especialmente a la luz de las restricciones geopolíticas.

Si bien no está tan concentrada como la capa de hardware, la computación en la nube está dominada globalmente por tres grandes empresas tecnológicas: Amazon Web Services (AWS), Microsoft Azure y Google Cloud Platform, que representan alrededor de dos tercios del mercado (Figura 11B). Los altos costos de cambio, las tarifas de salida y la integración vertical contribuyen a esta concentración. Los proveedores de servicios en la nube suelen ofrecer un ecosistema de servicios integrados, lo que consolida aún más su poder de mercado. Los altos costos fijos y los importantes efectos de red en la computación en la nube también favorecen a las empresas más grandes, lo que dificulta el afianzamiento de competidores más pequeños.⁴⁶


⁴⁵ "Conozca el chip Nvidia de \$10,000 que impulsa la carrera por la IA", CNBC, 23 de febrero de 2023; "¿Por qué los chips de Nvidia dominan la "¿Mercado de IA?", The Economist, 27 de febrero de 2024.

⁴⁶ Véase Ofcom (2023), Gartner (2024) y Biglaiser et al. (2024).

Los datos de entrenamiento son otro componente crucial de la cadena de suministro de la IA.⁴⁷ Históricamente, los modelos de IA de vanguardia se han basado en grandes cantidades de datos públicos. Sin embargo, a medida que disminuye el acervo de datos públicos, las empresas recurren a fuentes privadas. Las grandes empresas tecnológicas tienen una ventaja significativa gracias a su acceso a una gran cantidad de datos privados de usuarios de sus actividades comerciales principales. También pueden beneficiarse de los datos: bucle de retroalimentación de la actividad de la red, donde más usuarios generan más datos, mejorando los modelos de IA y atrayendo aún a más usuarios.⁴⁸ Las empresas más grandes con bolsillos más profundos también están mejor posicionadas para adquirir o asociarse con propietarios de datos más pequeños, consolidando aún más su poder de mercado.

59

FIGURA 11 ESTRUCTURA DEL MERCADO DE LA CADENA DE SUMINISTRO DE IA (%)



Notas: 1. Basado en los ingresos de 2023. 2. Basado en los ingresos del primer trimestre de 2024. 3. Tráfico en marzo de 2024. 4. Basado en el capital total invertido en 2023 en empresas dedicadas a la inteligencia artificial y el aprendizaje automático. Las grandes tecnológicas son Alibaba Cloud Computing, Alibaba Group, Alphabet, el Fondo de Innovación Industrial de Amazon, Amazon Web Services, Amazon, Apple, Google Cloud Platform, Google para startups, Microsoft, Tencent Cloud, Tencent Cloud Native Accelerator y Tencent Holdings.

Fuentes: IoT Analytics Research (2023); PitchBook Data Inc; Statista; Liu y Wang (2024); cálculos de los autores.

El capítulo 3 profundiza en las implicaciones de la abundancia de datos y la IA en los mercados financieros, destacando el papel de las grandes empresas tecnológicas en la configuración de la dinámica del mercado y los riesgos potenciales de la concentración del mercado.

48 Véase Agrawal et al. (2018), BIS (2019) y Gans (2024).

El mercado de modelos de base es dinámico, con más de 300 modelos proporcionados por 14 empresas. Si bien algunas empresas ofrecen modelos propietarios (p. ej., OpenAI, Google DeepMind), otras adoptan un enfoque de código abierto (en particular, Llama de Meta y, más recientemente, DeepSeek). Los modelos propietarios ofrecen una flexibilidad limitada y pueden ser costosos, mientras que los modelos de código abierto fomentan la competencia y la innovación.⁴⁹

A pesar de la variedad, el mercado ha estado dominado hasta ahora por unas pocas empresas como OpenAI, Google DeepMind, Anthropic y Meta. En 2023, GPT-4 de OpenAI representó el 69 % de los ingresos del mercado de IA generativa. Sin embargo, dada la naturaleza dinámica del mercado y el potencial para lograr eficiencias, la jerarquía podría cambiar rápidamente. Hasta ahora, el mercado se ha visto afectado por los altos costos fijos de los datos de entrenamiento y los recursos computacionales, estimándose el costo de entrenamiento de GPT-4 en más de 100 millones de dólares. No obstante, DeepSeek ha reducido significativamente estos costos, demostrando que los modelos base pueden entrenarse de forma más eficiente y económica.

Otra característica importante del mercado de modelos de base es una tendencia general hacia la integración vertical.⁵⁰ Si bien la integración vertical puede mejorar la eficiencia en muchos casos, también puede generar distorsiones, reducir la competencia y socavar la innovación si las empresas integradas verticalmente restringen el acceso de sus rivales a insumos esenciales o a mercados posteriores (exclusión descendente). Las empresas que producen modelos de base se integran cada vez más con proveedores anteriores y aplican cláusulas de exclusividad.

Por ejemplo, OpenAI utiliza exclusivamente Microsoft Azure para entrenar y almacenar sus modelos como parte de la inversión de Microsoft en Open AI. La exclusividad puede ser anticompetitiva cuando se presenta en ambos sentidos; por ejemplo, cuando un modelo base entrenado en un proveedor de servicios en la nube específico solo puede usarse para inferencia a través de dicho proveedor, como es el caso de Open AI y Microsoft Azure. Además, se incentiva a los productores de modelos base a adquirir o integrarse con productores de datos para asegurar datos de entrenamiento de alta calidad, que son cada vez más escasos.

La capa de la cadena de suministro de IA orientada al usuario, que incluye aplicaciones como ChatGPT, Gemini y FinGPT, sigue la dinámica de las plataformas digitales. Desde la llegada de ChatGPT a la IA, las aplicaciones basadas en modelos base han proliferado en diversos sectores de la economía, como la salud, la educación, el procesamiento y cumplimiento normativo de backend, y el desarrollo de software. A pesar de ello, al igual que con las plataformas digitales, existe el riesgo de que surjan dinámicas de "el ganador se lo lleva todo" en los mercados de aplicaciones de IA. Por ejemplo, ChatGPT aún representa el 60 % del mercado de chatbots, lo que pone de relieve la importancia de ser pionero en el mercado (Figura 11C).

⁴⁹ Korinek y Vipra (2024).
⁵⁰ CMA (2024).


2.2.3 El papel dominante de las grandes tecnológicas

La creciente influencia de las grandes empresas tecnológicas en la cadena de suministro de IA es uno de los avances más notables en el mercado de la IA. Estas grandes empresas ya ostentan un poder de mercado significativo en muchos mercados digitales y están ampliando esta influencia en los mercados emergentes de IA.

En 2023, representaron el 33% del capital total recaudado por empresas de IA y casi el 67% del capital recaudado por empresas de IA generativa (Figura 11D).⁵¹ Entre las inversiones notables se incluyen la inversión de 10 mil millones de dólares de Microsoft en OpenAI y las inversiones de Google y Amazon en Anthropic y Hugging Face.

Las grandes tecnológicas se están integrando verticalmente en todas las capas de la cadena de suministro de IA, lo que genera un nuevo bucle nube-modelo-datos (Figura 12). Gracias a su control sobre los recursos computacionales y a su ventaja comparativa en la producción, el almacenamiento y el análisis de datos, las grandes tecnológicas podrían proporcionar mejores modelos de IA. El uso de estos modelos genera más datos, que pueden ser utilizados óptimamente por los recursos computacionales de las grandes tecnológicas para mejorar sus modelos y aplicaciones de IA, lo que aumenta la eficiencia del procesamiento y el análisis de datos (la denominada «gravitación de los datos»). Este bucle se refuerza si también se producen efectos de red derivados del uso de los modelos. En definitiva, el bucle nube-modelo-datos hace probable que la cadena de suministro de IA siga estando dominada por un puñado de grandes empresas tecnológicas.

FIGURA 12 GRANDES TECNOLÓGICAS EN LA CADENA DE SUMINISTRO DE IA



Fuente: Gambacorta y Shreeti (2025).

Debido a la naturaleza de su modelo de negocio, las grandes tecnológicas pueden alcanzar rápidamente una posición dominante en el mercado financiero. Una vez que han consolidado una base de consumidores cautivos, pueden abusar de su posición dominante para impedir la entrada de competidores, aumentar los costes de cambio, agrupar productos y promocionar sus propios productos a expensas de terceros.

El riesgo de abuso de posición dominante en el mercado es especialmente grave, ya que las grandes plataformas tecnológicas sirven cada vez más como infraestructuras de venta esenciales para los proveedores de servicios financieros, pero también compiten con ellos al mismo tiempo. Por ejemplo, en China, el mercado de pagos móviles está dominado por dos grandes tecnológicas (Alipay y Tenpay), cuyos servicios son...

51 "Las grandes tecnológicas superan en gasto a las empresas de capital de riesgo en el frenesí de inversión en inteligencia artificial". Financial Times, 26 de diciembre de 2023.

No interoperable. En India, la mayoría de las transacciones de pago móvil en la Interfaz Unificada de Pagos (UPI) se realizan mediante aplicaciones de grandes empresas tecnológicas (aunque, para ser justos, estos servicios son interoperables en un sistema compartido).

62

Las grandes tecnológicas también podrían usar las enormes cantidades de datos que recopilan para obtener beneficios y discriminar precios entre sus clientes. Dado que los datos son un bien no rival, pueden generar economías de escala y de alcance. Gracias a su tamaño y tecnología, las grandes tecnológicas tienen el potencial de acumular cantidades significativas de datos a un coste mínimo. Estos datos pueden utilizarse no solo para evaluar la solvencia de un prestatario, sino también para identificar la tasa de interés máxima que los prestatarios están dispuestos a pagar por préstamos o la prima más alta que los clientes pagarían por un seguro. Una vez que estas empresas han adquirido una posición dominante, pueden utilizarla para discriminar precios y obtener beneficios excesivos.

Esto puede conducir a la aparición de «monopolios digitales».52

EFECTOS DE LA
MONOPOLIZACIÓN


La Figura 13 ilustra el mecanismo que subyace a la extracción del excedente del consumidor por parte de las grandes tecnológicas. El Panel A presenta el caso de referencia de competencia perfecta, donde los servicios financieros se fijan al coste marginal. El Panel B presenta el caso de un monopolio puro, donde el precio que pagan los consumidores es superior al coste marginal, la oferta de servicios es menor y existe una pérdida de bienestar asociada a la fijación de precios monopolísticos (en gris). El Panel C presenta el caso de los monopolios digitales (grandes tecnológicas) que utilizan big data y algoritmos sofisticados, y son capaces de identificar el precio de reserva de cada consumidor y establecer un precio personalizado justo por debajo. De esta forma, las grandes tecnológicas pueden aumentar la cantidad vendida por encima del nivel competitivo (Panel A) y eliminar la pérdida irrecuperable (Panel B).

Sin embargo, también extraen todo el excedente de los consumidores. El gráfico muestra que, en este caso, los consumidores se encuentran en peor situación que bajo un monopolio puro.

Las grandes tecnológicas pueden explotar aún más los sesgos conductuales de los consumidores a su favor y manipular sus preferencias. El panel D de la Figura 13 representa el caso en el que un monopolio digital persuade a sus consumidores a sobreestimar los beneficios de consumir su producto o servicio. En este caso, la curva de demanda se desplaza de D0 a D1, y algunos consumidores optan por comprar el producto aunque su valor real sea inferior al precio que pagan. Cualquier excedente adicional del consumidor solo se percibe (área roja clara) y se produce una pérdida de excedente para los consumidores incluso mayor que la que se produce con la discriminación de precios.

52 Véase Farboodi et al. (2019); BIS (2019).

FIGURA 13 ESTRUCTURAS ILUSTRATIVAS DEL MERCADO: DE LA COMPETENCIA AL MERCADO MANIPULACIÓN



Fuente: Boissay et al. (2021).

2.2.4 Estabilidad financiera

El uso generalizado de la IA también conlleva mayores riesgos para la estabilidad financiera. Incluso con capacidades limitadas, su uso temprano provocó desplomes repentinos e inestabilidad financiera. Ejemplos notables incluyen el desplome repentino de la bolsa estadounidense de 1987, causado en parte por la dependencia de las compañías de seguros de modelos basados en reglas.

Una IA más sofisticada, como los modelos de aprendizaje automático, han amplificado estos riesgos de varias maneras. En primer lugar, la mayoría de los modelos de IA se basan en conjuntos de datos similares. Debido a las economías de escala y alcance en la recopilación de datos, un pequeño número de actores importantes, a menudo grandes empresas tecnológicas, dominan la producción de conjuntos de datos relevantes utilizados para entrenar estos modelos. El uso de los mismos conjuntos de datos fundamentales subyacentes puede aumentar el riesgo de uniformidad y prociclicidad en las predicciones de los modelos. En segundo lugar, dado que las instituciones financieras dependen solo de unos pocos...

53 Shiller (1988).

En el caso de proveedores de modelos externos, también existe el riesgo de que se produzca un fenómeno de manada de modelos. Modelos y algoritmos de optimización similares pueden aumentar la volatilidad del mercado, aumentar la probabilidad de caídas repentinas y reducir la liquidez durante períodos de tensión.⁵⁴

En tercer lugar, la creciente interconexión de las redes en las finanzas y la economía real puede agravar los efectos perjudiciales de la IA en la estabilidad financiera. Para agravar estos desafíos, la falta de explicabilidad inherente a los modelos de IA puede impedir que los reguladores detecten a tiempo el riesgo sistémico o la manipulación del mercado.⁵⁵

El uso de modelos GenAI amplifica aún más estos riesgos. La automaticidad, velocidad y ubicuidad de GenAI pueden intensificar aún más el comportamiento gregario y la uniformidad. En particular, los agentes de IA⁵⁶ presentan riesgos sistémicos debido a sus acciones autónomas sin supervisión humana y a su posible desalineación con los objetivos a largo plazo.⁵⁷ Al centrarse estrictamente en objetivos como la maximización de beneficios, pueden ignorar consideraciones éticas como la estabilidad financiera y la prevención de riesgos. Incluso con restricciones regulatorias, estos agentes de IA podrían explotar las lagunas legales, apegándose a la letra pero no al espíritu de la ley. Por ejemplo, en un entorno simulado, un LLM que actuaba como operador de bolsa incurrió en tráfico ilegal de información privilegiada y mintió al ser descubierto.⁵⁸

A medida que la IA avanza hacia la inteligencia artificial general (IAG), estos riesgos podrían aumentar significativamente. La IAG se refiere a sistemas de IA capaces de realizar todas las tareas cognitivas que los humanos pueden realizar. A diferencia de la IA limitada, diseñada para tareas específicas, la IAG razonaría, resolvería problemas y pensaría de forma abstracta en diversos dominios, transfiriendo conocimiento como los humanos. De igual manera, la IA transformadora (IAT) se define como una IA lo suficientemente potente como para transformar radicalmente la sociedad y la economía, acelerando de forma autónoma el progreso científico, incluida la propia IA, o impulsando significativamente el crecimiento económico. Existe un intenso debate sobre si se logrará la IAG o la IAT y con qué rapidez, con fuertes opiniones en ambos bandos.⁵⁹

Un aspecto distinto, pero relacionado, es el impacto de la creciente concentración del mercado en las vulnerabilidades financieras. Como se ha mencionado, la cadena de suministro de IA se concentra en múltiples niveles: desde la producción de chips hasta la computación en la nube, los datos de entrenamiento y los modelos de base. Depender de los mismos proveedores de IA crea puntos únicos de fallo críticos. Por ejemplo, una filtración generalizada de datos, un error de software o un ataque a los modelos fundamentales de IA utilizados por múltiples instituciones podrían desencadenar efectos en cascada que perturben los mercados financieros globales.

54 OCDE (2021).

55 Véase Georges y Pereira (2021). Danielsson et al. (2022) examinan cómo la IA puede desestabilizar el sistema financiero al crear nuevos riesgos extremos y amplificar los existentes.

Entre las diversas definiciones de agentes LLM, definimos un agente como un LLM capaz de utilizar una computadora. Algunos ejemplos son Claude Computer Use (Anthropic, 2024), Operator (OpenAI, 2025) o Mariner (DeepMind, 2024).

57 Para un análisis exhaustivo del «problema de alineación», que surge cuando las acciones o los procesos de toma de decisiones de la IA Si no se alinean con los objetivos o valores previstos de los humanos, consulte el Capítulo 4.


58 Véase Chan et al. (2024) para los riesgos sistémicos que plantean los agentes de IA, Korinek y Balwit (2024) para los problemas con las restricciones regulatorias, y Scheurer et al. (2023) para un ejemplo de un LLM que actúa como corredor de bolsa. El capítulo 4 analiza la integración de la IA en la contratación financiera y la gobernanza corporativa, haciendo hincapié en la necesidad de modelos de gobernanza híbridos para garantizar la transparencia, la rendición de cuentas y la adaptabilidad ante el uso de agentes.

59 Si bien algunos líderes de la industria creen que la IAG o superinteligencia podría lograrse en los próximos cinco años (Morris et al., 2024; Amodei, 2024; Altman, 2024, 2025), otros sostienen que aún quedan obstáculos importantes (Browning y LeCun, 2022; Altmeyer et al. 2024). Para una discusión sobre TAGI, ver, entre otros, Suleyman y Bhaskar 2023.

Más allá de las vulnerabilidades derivadas de la organización industrial de la IA, las repercusiones de su uso en la economía real también podrían ser perjudiciales para la estabilidad financiera. En general, existe mucha incertidumbre sobre el impacto de la IA en el sector real, en particular en los mercados laborales y la productividad. Las primeras investigaciones sugieren que la IA puede aumentar la productividad, especialmente en tareas que requieren altas habilidades cognitivas y para trabajadores con menos experiencia. Si la IA se comporta como otras tecnologías de propósito general, podría aumentar la productividad, crear nuevas tareas y aumentar la demanda de mano de obra. Por otro lado, la IA también puede reemplazar trabajadores y tareas. El impacto general de la IA en el sector real dependerá del equilibrio entre el aumento de la productividad, la creación de tareas y la pérdida de empleos (Figura 14).⁶⁰

65

FIGURA 14 EL IMPACTO DE LA IA EN LA DEMANDA LABORAL Y LOS SALARIOS



Fuente: Aldasoro et al. (2024e).

En el escenario optimista, la adopción de la IA puede generar un impacto positivo en la productividad y disrupciones limitadas en el mercado laboral. En este caso, el impacto en la estabilidad financiera será limitado. En el escenario disruptivo, las capacidades de la IA avanzan muy rápidamente y causan disrupciones masivas en el mercado laboral y una redistribución de la riqueza. Esto puede conducir a impagos generalizados e inestabilidad financiera. La realidad probablemente se situará en un punto intermedio.

2.3 ¿CÓMO REGULAR LA IA?

Los responsables de las políticas se enfrentan al desafío de promover el uso de la IA para obtener beneficios al tiempo que protegen la seguridad del sistema financiero y las prácticas competitivas, y abordan la privacidad.


Para analizar cómo el desarrollo de la IA y la entrada de las grandes empresas tecnológicas en los servicios financieros impactan el debate político, podemos utilizar un “triángulo de políticas” que destaca tres compensaciones entre los objetivos de las políticas públicas: (i) estabilidad financiera e integridad del mercado; (ii) eficiencia y competencia; y (iii) privacidad de datos y protección del consumidor (Figura 15).⁶¹

Regulaciones,

⁶⁰ Véase Aldasoro et al. (2024d) para las repercusiones del uso de la IA en la economía real. Véase Brynjolfsson et al. (2023), Noy y Zhang (2023), Aldasoro et al. (2024c), Gambacorta et al. (2024c) y Peng et al. (2024) para investigaciones preliminares sobre el impacto de la IA en la productividad y los mercados laborales.

⁶¹ Véase Carletti et al. (2020) y Feyen et al. (2021).

FIGURA 15 COMPENSACIONES DE POLÍTICAS ENTRE LA IA Y LA TRANSFORMACIÓN DIGITAL EN LAS FINANZAS



Fuente: Carletti et al. (2020); Feyen et al. (2021).

Comencemos con el equilibrio tradicional entre estabilidad y competencia (flecha roja). Los reguladores han debatido durante mucho tiempo la relación entre competencia y estabilidad financiera. En general, es deseable una mayor entrada al mercado del sector financiero. Una mayor competitividad fomenta una competencia beneficiosa (al aumentar la innovación y la eficiencia) y reduce el poder de mercado de los operadores tradicionales. Sin embargo, como se analizó en la sección anterior, el uso de la IA y la entrada de las grandes tecnológicas en el sector financiero pueden aumentar la concentración y el poder de mercado.

Si bien la competencia y las soluciones más eficientes a menudo pueden beneficiar a los consumidores, surgen compensaciones entre la eficiencia/competencia y la privacidad/protección del consumidor. Por ejemplo, el uso de formas alternativas de datos que ayudan en la calificación crediticia podría afectar la privacidad o introducir distorsiones. Esto se representa con la flecha azul en la Figura 15. Curiosamente, Vives y Ye (2025b) concluyen que las fintech con menor eficiencia de monitoreo pueden ingresar con éxito al mercado crediticio debido a su mayor flexibilidad en los precios y que una mayor concentración bancaria conduce a un mayor volumen de préstamos fintech. Sin embargo, la ventaja de las fintech al ofrecer conveniencia también puede inducirlos a cobrar tasas de interés más altas que los bancos.

El intercambio de datos en los mercados crediticios puede mitigar los problemas de información asimétrica, y disponer de datos adecuados es crucial para supervisar la estabilidad e integridad financieras. Al mismo tiempo, en el caso de la IA y las limitadas salvaguardias para los consumidores, esto introduce un nuevo equilibrio entre la privacidad (y la protección del consumidor en general) por un lado, y la estabilidad financiera y la integridad del mercado por otro. Este equilibrio se representa con la flecha verde en la Figura 15.

62 Véase Claessens (2009) para un análisis de los beneficios de una mayor entrada al mercado en el sector financiero.

63 Vives y Ye (2025a) encuentran que las mejoras de TI afectan la competencia, la inversión y el bienestar dependiendo de su impacto en la distancia entre prestamista y prestatario y los costos de monitoreo, con diferentes efectos según la gravedad del riesgo moral.

64 Pagano y Jappelli (1993).

Principios para la regulación de la IA

Dada la diversidad de actores y las nuevas disyuntivas, las soluciones políticas para abordar los efectos perjudiciales de la IA no son sencillas. El camino hacia una regulación eficaz de la IA es complejo, ya que la cadena de suministro de IA abarca numerosos mercados que se encuentran bajo el control de distintas autoridades reguladoras, las cuales a menudo tienen objetivos contrapuestos, como se muestra en el triángulo de políticas anterior.⁶⁵

67

Equilibrar los beneficios y riesgos de la IA requiere una regulación proactiva e integral que anticipe problemas futuros e incorpore consideraciones tecnológicas, sociales y éticas. No todos los riesgos de la IA requieren intervención regulatoria; la regulación debe centrarse en aquellos riesgos que impactan objetivos políticos específicos, mientras que los mecanismos de mercado pueden gestionar otros. Dada la complejidad de la IA y los riesgos imprevistos, establecer principios regulatorios es crucial. Los organismos reguladores, tanto nacionales como internacionales, han establecido principios generales para regular y gestionar los sistemas de IA durante su desarrollo e implementación.⁶⁶ Los principios comunes incluyen el bienestar social, la transparencia, la rendición de cuentas, la equidad, la protección de la privacidad, la seguridad, la supervisión humana y la robustez.

Sin embargo, incluso si se logra un consenso en las políticas nacionales sobre estos principios, la cooperación internacional puede ser más difícil de alcanzar porque las jurisdicciones difieren en sus marcos jurídicos y enfoques regulatorios hacia la IA, lo que hace que la aplicación de principios simples sea difícil de lograr.

Modelos regulatorios para la IA

Se han identificado tres modelos principales de regulación de la IA en la literatura: el enfoque impulsado por el mercado de Estados Unidos enfatiza la innovación y la autorregulación; el modelo impulsado por el Estado de China utiliza la tecnología para fines políticos y el crecimiento de la industria; y el modelo impulsado por los derechos de la Unión Europea se centra en la protección de los derechos individuales y sociales. Si bien distintos, estos modelos están convergiendo lentamente hacia principios similares. En Estados Unidos, la regulación de la IA ha evolucionado hacia acciones ejecutivas como la Orden Ejecutiva de 2023 que aborda los daños de la IA, pero carece de legislación significativa. Las regulaciones de China enfatizan los valores socialistas y están avanzando hacia una Ley de IA. La Ley de IA de la Unión Europea (2024) introduce un marco basado en el riesgo que categoriza los sistemas de IA, prohíbe aquellos que plantean riesgos inaceptables y establece requisitos estrictos para las aplicaciones de alto riesgo.

⁶⁵ Tomemos, por ejemplo, los objetivos contrapuestos de mantener la privacidad del usuario y tener portabilidad e interoperabilidad de datos para garantizar la igualdad de condiciones para las empresas más pequeñas.

⁶⁶ Por ejemplo, la Unión Europea desarrolló la Lista de Evaluación para la Inteligencia Artificial Confiable (ALTAI) (Ala-Pietilä et al., 2020; Unión Europea, 2024). En Estados Unidos, el Instituto Nacional de Estándares y Tecnología (NIST) describió las características de la confiabilidad en su Marco de Gestión de Riesgos de IA (NIST, 2023). China también ha definido principios de IA responsable (Ministerio de Tecnología de China, 2019). Además, la Organización Internacional de Normalización (ISO) proporciona orientación sobre la gestión de riesgos para los sistemas de IA a través de normas como la ISO/IEC 23894:2023. Estos marcos constituyen la piedra angular de muchas iniciativas regulatorias de IA. Véase Aldasoro et al. (2024d) para un análisis más completo.

Los responsables políticos están implementando los principios regulatorios de la IA en toda la cadena de valor (diseño, implementación y difusión) mediante marcos como la Ley de IA de la UE, el Marco de Gestión de Riesgos de IA del NIST y las disposiciones de IA Generativa de China. Estos esfuerzos se centran en la gobernanza, la visibilidad, la evaluación y la gestión de riesgos para garantizar la resiliencia sistémica de la IA Generativa y los agentes de IA en el sector financiero.

Cooperación internacional

Como los datos y la tecnología no tienen fronteras, la cooperación global en la regulación de la IA es esencial. Se necesitan estándares regulatorios comunes, en particular sobre las reglas de gobernanza de la IA y las metodologías de evaluación de riesgos. Estandarizar las reglas de gobernanza de la IA a nivel internacional es crucial para garantizar estándares éticos y de seguridad consistentes, prevenir el arbitraje regulatorio y fomentar la cooperación global. Unas directrices uniformes pueden aumentar la confianza, facilitar las aplicaciones transfronterizas de la IA y abordar eficazmente desafíos globales como la privacidad, la seguridad y el acceso equitativo. También se necesitan metodologías estandarizadas para la evaluación de riesgos de los modelos de IA que consideren sus atributos únicos, como la adaptabilidad y el aprendizaje a lo largo del tiempo. Estas metodologías deben considerar la posibilidad de que los sistemas de IA desarrollen comportamientos o resultados imprevistos, lo que requiere una supervisión continua y la capacidad de ajustar las medidas regulatorias a medida que la tecnología madura y se integra más profundamente en las infraestructuras sociales.⁶⁷

2.4 CONCLUSIONES

La IA está transformando significativamente el sector financiero al mejorar el procesamiento de la información, la gestión de riesgos y la atención al cliente. Ofrece importantes oportunidades de eficiencia e innovación, especialmente en áreas como el análisis de riesgo crediticio, el asesoramiento robótico, el cumplimiento normativo y la atención al cliente. Sin embargo, también presenta desafíos, como la opacidad de los modelos, la dependencia de los datos, los sesgos, las amenazas a la ciberseguridad y los problemas de estabilidad sistémica.

La adopción generalizada de la IA en el sector financiero puede agravar riesgos como la concentración del mercado, la concentración de modelos y la uniformidad, lo que puede generar inestabilidad financiera. La posibilidad de que la IA agrave los problemas de privacidad del consumidor y los riesgos legales complica aún más su integración en el sistema financiero. Además, el dominio de las grandes empresas tecnológicas en la cadena de suministro de la IA plantea importantes desafíos competitivos y regulatorios que deben supervisarse.

⁶⁷ La colaboración global en IA se centra en garantizar la seguridad y transferir conocimientos y mejores prácticas para asegurar que todas las regiones del mundo puedan beneficiarse de los avances de la IA de forma responsable. Iniciativas como el Proceso de Hiroshima del G7 (firmado en diciembre de 2023) y el Consejo Transatlántico de Comercio y Tecnología (última reunión en abril de 2024) subrayan la importancia de la colaboración internacional para establecer normas para el uso seguro y ético de la IA. Más recientemente, en la Cumbre de Acción sobre IA de febrero de 2025 en París, alrededor de 60 países firmaron una declaración que promueve la IA inclusiva y sostenible, haciendo hincapié en la cooperación global, la seguridad y el desarrollo ético. El acuerdo, copatrocinado por Francia e India, tenía como objetivo garantizar que la IA beneficie a todas las naciones, en particular al Sur Global. La cumbre también vio el lanzamiento de "Current AI", una iniciativa de 400 millones de dólares que apoya proyectos de IA de interés público. La declaración refleja los crecientes esfuerzos internacionales para equilibrar la innovación con la gobernanza responsable de la IA.

Una regulación y gobernanza eficaces son esenciales para aprovechar los beneficios de la IA y mitigar los riesgos asociados. Los responsables políticos deben equilibrar la innovación con la gestión de riesgos, garantizando la transparencia, la equidad y los estándares éticos. La cooperación internacional es crucial para armonizar la gobernanza de la IA y evitar el arbitraje regulatorio.

La estandarización de las reglas de gobernanza de la IA y las metodologías de evaluación de riesgos puede mejorar la colaboración global y abordar desafíos como la privacidad, la seguridad y el acceso equitativo.

69

La interconexión entre los avances de la IA y la economía en general genera posibles efectos indirectos entre la economía real y el sistema financiero. A medida que la IA permea las operaciones comerciales y los procesos de toma de decisiones, sus implicaciones para el empleo, la productividad y la distribución del ingreso requieren una cuidadosa consideración. Las respuestas políticas deben prepararse para diversos escenarios, desde aumentos de productividad hasta importantes disrupciones en el mercado laboral, para garantizar un crecimiento económico inclusivo y la estabilidad.

De cara al futuro, el impacto de la IA en las finanzas dependerá drásticamente de la evolución de la tecnología. Existen diferentes escenarios posibles. A corto y medio plazo, el impacto de la IA será más limitado si los copilotos basados en LLM amplían, en lugar de reemplazar, las habilidades y los trabajadores humanos del sector financiero. Los efectos serán mayores si los "agentes" de la IA se vuelven cada vez más capaces e independientes, reemplazando en última instancia muchas funciones humanas. A largo plazo, el logro de la IAG o la superinteligencia podría revolucionar aún más el funcionamiento del sector financiero y la economía en general. A pesar de esta incertidumbre sobre los escenarios futuros, es imperativo que la regulación considere los avances tecnológicos deseados, las habilidades y las tareas que se pueden automatizar, y garantice que estas tecnologías respeten los derechos fundamentales para un mayor beneficio social.

CAPÍTULO 3

El impacto de la IA en las finanzas: la transformación de la información y sus consecuencias

71

La inteligencia artificial y la abundancia de datos están transformando la forma en que se produce y utiliza la información en los mercados financieros. Esta evolución puede tener consecuencias de gran alcance. De hecho, como escribe Stiglitz (1994, p. 23), «los mercados financieros [...] pueden considerarse el 'cerebro' de todo el sistema económico, el centro de la toma de decisiones: si fallan, no solo las ganancias del sector serán menores de lo que habrían sido de otro modo, sino que el rendimiento de todo el sistema económico podría verse afectado».

Según esta analogía, si la abundancia de datos y la IA mejoran la calidad de la información que fluye hacia los mercados financieros y las decisiones que se toman con base en ella, el sistema económico se beneficiará de una mejor comprensión de su "cerebro". Esto debería conducir a una asignación de capital más eficiente y fomentar el crecimiento económico. Por el contrario, si estas tecnologías degradan la calidad de la información financiera, esto generaría preocupación y podría justificar la intervención política.

En este contexto, el objetivo de este capítulo es explorar cómo la abundancia de datos y la IA impactan en la producción de información financiera del sector financiero, destacando los beneficios potenciales de esta evolución y sus posibles riesgos. El capítulo se centra en el sector de valores, es decir, en los intermediarios que gestionan los ahorros de los inversores (el lado comprador, fondos mutuos, fondos de cobertura, etc.) y en quienes ayudan a los inversores a reequilibrar sus carteras (el lado vendedor, creadores de mercado, corredores, bolsas, etc.). La IA y la abundancia de datos también impactan a otros actores importantes del sistema financiero, en particular a los bancos y las empresas, como se analiza en los capítulos 2 y 4 de este informe, respectivamente.

Un papel clave de la industria financiera en general –y de la industria de valores en particular– es producir y negociar contratos financieros que los consumidores de servicios financieros utilizan para compartir riesgos, transferir recursos o proporcionar incentivos.⁶⁸ Para desempeñar esta función, los intermediarios financieros (bancos, creadores de mercado, suscriptores, gestores de fondos, etc.) deben producir información (sobre flujos de efectivo futuros, riesgo de contraparte, costo del capital, etc.), y muchas ocupaciones en la industria de valores se relacionan con la recopilación, limpieza y procesamiento de información.

⁶⁸ Phillipon (2015).

La IA transforma la forma en que el sector financiero produce y utiliza la información, ya que permite a los participantes obtener predicciones más precisas (de flujos de caja futuros para proyectos de inversión, riesgo de impago de préstamos o rentabilidad de valores) a un menor coste, así como automatizar la búsqueda de información y la toma de decisiones basadas en ella. Como se explica en detalle en la Sección 3.1, esta posibilidad se debe a una combinación de tres factores: (i) un mayor volumen y diversidad de datos, que permite a los participantes utilizar más predictores para la previsión; (ii) algoritmos más potentes (de aprendizaje automático y de autoaprendizaje) para extraer información de los datos y utilizarla para la toma de decisiones; y (iii) una reducción del coste de dichos algoritmos gracias a la reducción de los costes de computación.

Por lo tanto, la IA supone un shock tecnológico: reduce el coste de la producción de información financiera y sustituye el juicio humano por inteligencia artificial para el procesamiento de la información y la toma de decisiones. No es sorprendente que la industria de valores haya aprovechado rápidamente esta evolución, como lo demuestra el auge del trading algorítmico (Sección 3.2.1), los fondos cuantitativos (Sección 3.2.2) y los robo-advisors (Sección 3.2.3).⁶⁹

La adopción de la IA en el sector de valores es muy prometedora. Debería generar mejoras de eficiencia mediante la reducción de costes y una toma de decisiones potencialmente más eficaz.

Si estos beneficios se trasladan a los consumidores de servicios financieros (hogares, empresas y gobiernos), estos se verán beneficiados. En la sección 3.3, destacamos cuatro obstáculos que podrían dificultar la materialización y la transmisión de estos beneficios a los consumidores de servicios financieros:

- El riesgo de que los intermediarios utilicen los avances en las tecnologías de la información para producir información con un valor social relativamente bajo porque no existe un mecanismo que recompense a los intermediarios por asignar su capacidad de producción de información a su uso más valioso para la sociedad (Sección 3.3.1).
- El riesgo de que los avances en las tecnologías de la información incrementen las asimetrías informativas y, por consiguiente, los costos de selección adversa para los participantes que no puedan seguir el ritmo de la tecnología (Sección 3.3.2). En última instancia, estos costos se suman a los costos de intermediación (alguien debe asumirlos) y, por lo tanto, podrían reducir las ganancias de eficiencia asociadas con la adopción de herramientas de IA por parte del sector de valores. Además, para captar rentas informativas, los intermediarios podrían involucrarse en carreras de inversión socialmente derrochadoras en poder de computación y capital humano.
- El riesgo de que los algoritmos de aprendizaje por refuerzo aumenten el poder de mercado de algunos intermediarios, en particular los creadores de mercado algorítmicos (Sección 3.3.3). De ser así, los costos de peso muerto reducirán las ganancias de bienestar derivadas de la adopción de la IA en el sector financiero.
- El riesgo de mercados de valores más frágiles debido a la naturaleza de “caja negra” de los algoritmos de aprendizaje automático (Sección 3.3.4).

⁶⁹ La figura 3 de Acemoglu et al. (2022) muestra que las ocupaciones en la industria financiera se encuentran entre las más expuestas a la IA, y que la proporción de vacantes relacionadas con la IA en las finanzas ha aumentado rápidamente en los últimos años.

Vale la pena destacar que este capítulo no describe cómo se pueden usar las técnicas de IA para avanzar en cuestiones de frontera en la economía financiera.⁷⁰ En cambio, se centra en cómo la IA afecta la producción y el uso de información financiera y los efectos resultantes sobre la eficiencia de los mercados de valores medidos de diversas maneras (informatividad de precios, liquidez, distribución de riesgos, estabilidad, etc.).

73

3.1 ¿POR QUÉ LA INFORMACIÓN FINANCIERA ESTÁ SIENDO MODIFICADA POR LA IA?

En esta sección, presentamos los tres factores que impulsan la rápida adopción de herramientas de IA en el sector financiero:

(i) abundancia de datos, (ii) técnicas eficaces para transformar datos en predicciones y decisiones, y (iii) una reducción del coste de estas técnicas gracias a menores costes de computación. La combinación de estos factores permite a los participantes del sector de valores producir y utilizar información a un menor coste.

3.1.1 Abundancia de datos

Tradicionalmente, los productores de información en los mercados de valores (por ejemplo, los analistas de valores) han confiado en los datos divulgados por las empresas (por ejemplo, los datos contables) para pronosticar los rendimientos de los activos y tomar decisiones financieras (por ejemplo, si proporcionar capital o no).

Estos datos siguen siendo relevantes, y las herramientas de IA pueden utilizarse para realizar predicciones (por ejemplo, mediante algoritmos de procesamiento del lenguaje natural para obtener señales de compra o venta a partir de nuevas presentaciones regulatorias). Sin embargo, dos nuevas fuentes de datos han surgido como importantes fuentes de información para el sector de valores: (i) datos alternativos y (ii) datos de mercado. Como se explica a continuación, estos datos han incrementado considerablemente el volumen y la variedad de nuevos datos relevantes para las decisiones financieras y la valoración de activos, así como la velocidad con la que estos datos están disponibles (las tres "V" de la revolución del big data).

Datos alternativos

En los últimos veinte años hemos asistido a un aumento espectacular de la disponibilidad de «conjuntos de datos alternativos». A diferencia de las fuentes tradicionales de información sobre corporaciones (por ejemplo, presentaciones regulatorias y estados financieros), estos datos no son necesariamente generados ni divulgados por las empresas. Más bien, provienen de la huella digital dejada por diversas actividades (compras, comercio, navegación web, viajes, etc.).


Los ejemplos de conjuntos de datos alternativos incluyen datos de geolocalización (por ejemplo, señales de GPS de dispositivos móviles), datos de redes sociales (por ejemplo, texto en publicaciones o imágenes en plataformas sociales), reseñas de productos de los consumidores, datos de tarjetas de crédito, imágenes satelitales (por ejemplo, imágenes de estacionamientos de minoristas, sitios de producción o actividad de envío), datos de sensores (por ejemplo, grabaciones de actividad industrial o emisiones de carbono) y datos de tráfico web y flujo de clics.

Numerosos artículos de investigación en economía y finanzas utilizan herramientas de IA. Véase, por ejemplo, Kelly y Xiu (2023) para un estudio de sus aplicaciones en la valoración de activos y la gestión de carteras.

Como se muestra en la Figura 16, un número cada vez mayor de proveedores (incluidas empresas como Eagle Alpha, Yipitdata, Kayros, RS Metrics, Datarade, etc.)⁷¹ recopilan datos alternativos y los venden a compradores como empresas de tecnología financiera, empresas, administradores de fondos, bancos o analistas de valores.⁷² El surgimiento de este mercado de datos alternativos es en sí mismo un cambio significativo en el mercado de información financiera.⁷³

74

FIGURA 16 NÚMERO ESTIMADO DE PROVEEDORES DE DATOS ALTERNATIVOS



Como resultado de esta evolución, la cantidad y diversidad de datos disponibles para los participantes del mercado financiero para predecir los retornos de los activos y los flujos de efectivo han aumentado considerablemente con el tiempo, y una gran cantidad de estudios académicos demuestran que los conjuntos de datos alternativos ahora brindan información valiosa sobre los retornos de las acciones, las ganancias corporativas y el riesgo crediticio.⁷⁴

Dado que las empresas no controlan las fuentes de datos alternativos, estas cambian la forma en que estas deben comunicarse con los inversores. En consecuencia, el auge de los datos alternativos podría transformar la divulgación corporativa y su regulación. Esta implicación se analiza con más detalle en el capítulo 4.

71 El número de proveedores de datos alternativos en la Figura 16 se obtiene de JP Morgan (2019), que proporciona una lista de datos Proveedores de interés para el sector financiero. El número real de proveedores de datos alternativos es mayor. Por ejemplo, en 2024, Datarade contaba con unos 2500 proveedores de datos alternativos y más de 22 000 conjuntos de datos.

72 Grennan y Michaely (2020) encuentran que aproximadamente el 50% de las fintechs especializadas en inteligencia de mercado venden señales financieras. Chi et al. (2023) muestran que los informes de los analistas de acciones del lado vendedor mencionan cada vez más el uso de datos alternativos como fuente de información.

Esta evolución plantea cuestiones interesantes sobre la valoración y la fijación de precios de los datos financieros (Farboodi et al., 2024).

74 Ejemplos de tales estudios incluyen a Jame et al. (2016), Huang (2018), Bartov et al. (2018), Green et al. (2019), Benamar et Alabama. (2021), Grennan y Michaely (2021), Jin (2023), Katona et al. (2025) y Dessaint et al. (2024), entre muchos otros. Green et al. (2019), por ejemplo, estudian el grado de información de las calificaciones de los empleadores en Glassdoor (una plataforma de reseñas y contratación de empresas donde los empleados pueden compartir información sobre sus empresas). Observan que las carteras ponderadas por valor de las empresas con las mayores mejoras trimestrales en las calificaciones de los empleadores superan a las que presentan descensos en dichas calificaciones. Katona et al. (2025) demuestran que los datos diarios de imágenes satelitales sobre la utilización de los estacionamientos en los comercios minoristas estadounidenses pueden utilizarse para predecir las ganancias y la rentabilidad de las acciones de estos comercios en el siguiente trimestre.

Datos de mercado

El proceso de negociación en los mercados de valores también genera una gran cantidad de datos con actualizaciones muy frecuentes, como se muestra en la Figura 17. De hecho, cada orden (p. ej., la presentación de una nueva orden limitada, su revisión o cancelación) para un valor en una plataforma de negociación electrónica genera un nuevo punto de datos. A su vez, este punto de datos es una fuente potencial de información para las decisiones que toman los participantes del mercado.

75

FIGURA 17 UN MILISEGUNDO DE ACTIVIDAD DE PEDIDO PARA UNA ACCIÓN ESTADOUNIDENSE

Time	Millis	Exchange	Action	Type	Size	Remaining	Price	Duration	Order-ID
10:01:49	77.871	EDGE-A	QUOTE	BID	700		12.18		ORDER-123455578
10:01:49	77.877	NASDAQ	CANCEL	ASK	3800	0	12.19	0.006824	ORDER-223458675
10:01:49	77.888	EDGE-X	CANCEL	BID	100	0	12.18	13.018484	ORDER-890767564
10:01:49	77.888	EDGE-X	QUOTE	BID	100		12.13		ORDER-224564478
10:01:49	77.983	PHLX	CANCEL	BID	4000	0	12.16	37.218454	ORDER-990871856
10:01:49	77.993	NYSE	QUOTE	ASK	300	3200	12.19	0.000155	ORDER-NA
10:01:49	78.029	NASDAQ	CANCEL	BID	4300	0	12.17	13.017681	ORDER-231565236
10:01:49	78.032	BATS-Z	QUOTE	BID	100		12.17		ORDER-85784
10:01:49	78.041	PHLX	CANCEL	BID	8400	0	12.17	16.369599	ORDER-667728645
10:01:49	78.078	NASDAQ	QUOTE	ASK	3800		12.19		ORDER-NA
10:01:49	78.086	BATS-Z	CANCEL	BID	7400	0	12.17	13.017709	ORDER-465988641
10:01:49	78.103	PHLX	CANCEL	BID	4000	0	12.16	16.369565	ORDER-164952269
10:01:49	78.146	EDGE-A	CANCEL	BID	100	0	12.17	37.527492	ORDER-852962674
10:01:49	78.169	EDGE-X	CANCEL	ASK	400	0	12.19	0.000332	ORDER-776645974
10:01:49	78.169	EDGE-X	CANCEL	ASK	400	0	12.19	0.000317	ORDER-102696697
10:01:49	78.213	PHLX	CANCEL	BID	6100	0	12.17	13.017743	ORDER-588461236
10:01:49	78.219	EDGE-X	CANCEL	BID	2800	0	12.17	13.017629	ORDER-554185558
10:01:49	78.341	LAVA	CANCEL	BID	100	0	12.18	3.147924	ORDER-365786456
10:01:49	78.662	EDGE-A	TRADE	SELL	700	0	12.18	0.000791	ORDER-123455578

Nota: La primera y la última orden se combinan y corresponden a una operación. Las demás órdenes son cancelaciones o la emisión de nuevas órdenes límite (cotizaciones).
Fuente: sitio web de la Comisión de Bolsa y Valores de Estados Unidos (<https://www.sec.gov/securities-topics/market-structure-analytics/midas-market-information-data-analytics-system>).

Por ejemplo, los inversores institucionales y sus corredores necesitan información en tiempo real sobre las cotizaciones en varios mercados como insumos para los algoritmos de ejecución que utilizan para minimizar los costos de negociación y lograr la "mejor ejecución".75

El acceso a datos de mercado en tiempo real también es crucial para los algoritmos utilizados por las firmas de trading por cuenta propia especializadas en creación de mercado y arbitraje (véase la Sección 3.2.1). En particular, las firmas de trading de alta frecuencia exigen un acceso extremadamente rápido a los datos sobre las cotizaciones publicadas en diferentes libros de órdenes limitadas para un valor (la Figura 17 muestra cotizaciones de siete plataformas diferentes, por ejemplo) para poder cancelar y actualizar rápidamente sus cotizaciones cuando se disponga de nueva información y obtener beneficios aprovechando oportunidades de arbitraje de muy corta duración, debido, por ejemplo, a la lenta adaptación de los precios en las diferentes plataformas a la nueva información (véase la Sección 3.2.1). En consecuencia, existe una demanda significativa de datos de mercado entre los participantes del sector financiero, y las bolsas obtienen una parte cada vez mayor de sus ingresos de la venta de los datos generados en sus plataformas de trading.76

75 Véase, por ejemplo, Greenwich Associates (2017), que informa los resultados de una encuesta a 69 gestores de activos y fondos de cobertura. Los fondos se basan en el valor de diversos tipos de datos, incluidos los datos de mercado. El 70 % de los encuestados indica que los datos de mercado en tiempo real y los datos históricos de mercado son los que ofrecen la mayor ventaja competitiva.
76 Consulte el Capítulo 4 de Duffie et al. (2022) para un análisis del mercado de datos de mercado.

Las bolsas venden datos de mercado de diversas maneras. En primer lugar, ofrecen datos en tiempo real, ya sea directamente a los inversores o a través de proveedores de datos como Bloomberg o Refinitiv, sobre operaciones y cotizaciones en sus plataformas de negociación. Estas ofertas varían en el nivel de granularidad de los datos.⁷⁷ En segundo lugar, las bolsas alquilan espacio en rack en sus centros de datos, una práctica conocida como «coubicación». La coubicación permite a los operadores de alta frecuencia ejecutar sus algoritmos cerca de los motores de comparación de la bolsa, lo que les permite recibir datos de mercado y ejecutar acciones basadas en estos datos con mayor rapidez que otros participantes del mercado.

En los últimos años, los participantes de la industria se han quejado de que las comisiones que cobran las plataformas de negociación por los datos de mercado son excesivamente altas.⁷⁸ Los mercados de valores en Europa y Estados Unidos están altamente fragmentados en el sentido de que la misma acción se negocia en múltiples plataformas de negociación (de nuevo, véase la Figura 17 para un ejemplo). En tales entornos, los corredores e inversores deben suscribirse a los feeds de datos de cada bolsa para tomar decisiones de enrutamiento óptimas, como dirigir las órdenes de mercado a las plataformas de negociación que ofrecen las mejores cotizaciones para una acción. En algunos casos, como en Estados Unidos, las mejores cotizaciones se consolidan y se difunden a los participantes del mercado a un bajo coste, pero con un ligero retraso, lo que hace que la cinta consolidada sea un sustituto imperfecto de los feeds de datos en tiempo real de las bolsas. Como resultado, los feeds de datos de varias bolsas no son sustitutos perfectos, lo que otorga a las bolsas un cierto grado de poder de mercado.

3.1.2 De los datos a las predicciones y decisiones: algoritmos de aprendizaje automático

Pronóstico

Los datos no son informativos por sí mismos; se necesita una tecnología para transformarlos en información procesable. Por esta razón, habría sido difícil aprovechar los datos alternativos y de mercado para la producción de información sin los avances en el procesamiento de la información, en particular el desarrollo del aprendizaje automático.⁷⁹

Los algoritmos de aprendizaje automático (redes neuronales, árboles de decisión y bosques aleatorios, regresiones de cresta y lazo, métodos de procesamiento del lenguaje natural, etc.) se basan en grandes cantidades de datos (la entrada de estos algoritmos) para generar predicciones (la salida). En el aprendizaje supervisado, estos algoritmos están diseñados para aprender la relación entre un conjunto de variables (características), $x_i = (x_{i1}, x_{i2}, \dots, x_{iN})$, y una variable de resultado (objetivo o etiqueta), y_i (donde i se refiere a un punto de datos).⁸⁰

Por ejemplo, las bolsas cobran diferentes tarifas por el acceso únicamente a los datos de la última operación y del tope del libro (las mejores cotizaciones y el número de acciones ofrecidas a estos precios) y a todo el libro de órdenes limitadas. También cobran diferentes tarifas según si los datos son para uso interno o para redistribución externa. Véase <https://www.nyse.com/publicdocs/nyse/data/> para obtener una lista de los datos vendidos por la NYSE y su escala de precios.

⁷⁸ "Los inversores europeos se quejan del aumento vertiginoso de los costes de los datos", Financial Times, 4 de abril de 2019.

⁷⁹ Kelly y Xiu (2023) definen el aprendizaje automático como "(i) una colección diversa de modelos de alta dimensión para predicción, combinada con (ii) métodos de "regularización" para la selección de modelos y mitigación del sobreajuste, y (iii) algoritmos eficientes para buscar entre un gran número de especificaciones potenciales de modelos".

⁸⁰ El aprendizaje es "supervisado" en el sentido de que durante la fase de entrenamiento, se le dice al algoritmo, después de seleccionar una acción (por ejemplo, después de hacer un pronóstico), cuál fue la acción correcta (por ejemplo, la realización real de la variable pronosticada).

Por ejemplo, las características pueden ser los valores numéricos de color de los píxeles en la imagen de un animal y el objetivo puede ser el tipo de animal (un perro o un gato). El algoritmo primero se "entrena" en un gran número de imágenes (realizaciones de valores x e y) para aprender la relación ('modelo') entre las características y el objetivo. El modelo resultante puede usarse entonces para predecir tipos de animales cuando se presentan nuevas imágenes al ordenador ('fuera de muestra'). El modelo se selecciona para minimizar una medida del error de predicción promedio (p. ej., el error cuadrático medio). Hay aprendizaje en el sentido de que, en la muestra, se conoce el objetivo verdadero y se puede interpretar el algoritmo como (i) hacer una predicción $\hat{y}$ basada en x ; (ii) observar la verdadera realización, y , del objetivo; y (iii) ajustar el modelo en función del error entre su predicción y el objetivo real.

77

De forma más general, considere el problema de predecir Y (p. ej., el rendimiento de una acción) con un vector de variables X (p. ej., diversas características de la acción) para minimizar el error cuadrático esperado de pronóstico. La solución al problema es la función $f(X)$ que minimiza $E((Y - f(X))^2)$, donde $E(\cdot)$ es el operador de expectativa. Es bien sabido que $f(X) = E(Y|X)$.

Sin embargo, sin conocer las distribuciones de Y y X , no se puede calcular $E(Y|X)$.

En cambio, se puede utilizar un conjunto de realizaciones de Y y X (datos de entrenamiento) para encontrar una función $\hat{f}(X)$ que sea una buena aproximación de $f(X)$ (por ejemplo, en el sentido de que minimiza el error cuadrático medio de predicción empírica). Los algoritmos de aprendizaje automático son métodos para encontrar $\hat{f}(X)$.

Estos algoritmos presentan varias características importantes. En primer lugar, son de alta dimensión, ya que el número de características puede ser muy elevado. En segundo lugar, difieren en el tipo de especificación permitida para $\hat{f}(X)$.⁸¹ Especificaciones más complejas permiten un mejor ajuste de los datos dentro de la muestra, pero conllevan el riesgo de un rendimiento deficiente fuera de la muestra debido al sobreajuste. Los algoritmos de aprendizaje automático (ML) están diseñados para limitar este riesgo mediante diversas técnicas denominadas «métodos de regularización». En tercer lugar, los algoritmos de ML pueden gestionar datos en formato no estructurado, como texto, imágenes o voces.

Los algoritmos de aprendizaje automático (ML) son importantes en finanzas porque muchos problemas financieros implican problemas de predicción. Por ejemplo, los gestores de fondos activos buscan señales que puedan predecir los rendimientos de los valores y evalúan si las estrategias de negociación (carteras) basadas en estas señales generan rendimientos anormales promedio significativos ('alfas'). Además, sus corredores necesitan pronosticar cambios futuros en la liquidez y movimientos de precios a corto plazo para ejecutar las órdenes de los gestores de fondos a bajos costos (véase la Sección 3.2.1). Los analistas de valores realizan pronósticos de las ganancias de las empresas en varios horizontes, formulando recomendaciones de inversión basadas en estas predicciones. La valoración y el presupuesto de capital de las empresas requieren pronosticar los flujos de efectivo en varios horizontes. Los bancos y las agencias de calificación desarrollan modelos para predecir el riesgo crediticio de los prestatarios. Los capitalistas de riesgo seleccionan proyectos en función de su probabilidad de éxito (por ejemplo, salida exitosa a través de una IPO).

⁸¹ Por ejemplo, las redes neuronales permiten una especificación altamente no lineal con una cantidad muy grande de parámetros a considerar. estimación, mientras que las regresiones de cresta consideran una especificación lineal con muchas variables explicativas y una penalización L2 para evitar el sobreajuste.

En consecuencia, una literatura de rápido crecimiento está utilizando ML para estudiar problemas de predicción en finanzas, como la predicción de retornos de acciones, ganancias corporativas, riesgo crediticio, liquidez o resultados de fracaso/éxito de la inversión en empresas emergentes.⁸² Una conclusión clave de estos estudios es que los pronósticos impulsados por IA son más precisos que los pronósticos producidos por modelos más simples o predicciones humanas.^{83,84} Este hallazgo refleja la capacidad de las máquinas para procesar conjuntos de información significativamente más grandes que los humanos y el hecho de que están exentas de sesgos cognitivos humanos.⁸⁵ Además, a diferencia de los humanos, las máquinas no se ven afectadas por conflictos de intereses y problemas de agencia (las máquinas no necesitan ser incentivadas para producir señales precisas).⁸⁶

Otra conclusión importante de esta literatura es que la combinación de pronósticos basados en humanos con pronósticos de ML puede generar mejores predicciones que confiar solo en pronósticos de ML.

Esta observación sugiere que los humanos poseen habilidades predictivas únicas, posiblemente debido a una forma de análisis que no puede ser replicada por las máquinas (por ejemplo, se basan en modelos del mundo) o porque los humanos tienen acceso a información que no está disponible para los algoritmos de ML.

Por ejemplo, Cao et al. (2024) comparan los pronósticos de ML con los pronósticos de los analistas de renta variable sobre la rentabilidad de las acciones a un año. Estos permiten que los pronósticos de ML aprovechen un amplio conjunto de predictores, incluyendo variables contables a nivel de empresa, variables a nivel de sector y variables macroeconómicas, junto con los pronósticos de los analistas. Los autores concluyen que los pronósticos de ML son más precisos que los pronósticos de los analistas: de 922.157 pronósticos realizados entre 2001 y 2018,

⁸² Para la predicción de los rendimientos de las acciones, véase, por ejemplo, Chincó et al. (2019), Gu et al. (2020), Murray et al. (2024), Brogaard y Zareei (2023), Chen et al. (2023a), Chen et al. (2023b) y Nagel (2021) para una presentación de libro de texto. Para la predicción de ganancias corporativas, véase, por ejemplo, Cao y You (2024), Chen et al. (2022a), da Silva y Thesmar (2024), Dong (2024) o Van Binsbergen et al. (2023). Para la calificación crediticia y la predicción del riesgo crediticio, véase, por ejemplo, Lessman et al. (2015), Jansen et al. (2024), Fuster et al. (2019, 2022), Hurlin et al. (2024) o Hué et al. (2023). Para predecir la liquidez futura, véase Easley et al. (2021) y para medir la negociación informada, véase Bogousslavsky et al. (2024).

Para la predicción del fracaso o resultado de la inversión temprana en empresas emergentes, véase Retterath (2020) o Lyonnet y Stern (2024).

⁸³ Por ejemplo, Cao y You (2024) comparan el rendimiento predictivo de los algoritmos de aprendizaje automático (árboles de decisión y redes neuronales artificiales) para las ganancias corporativas con el rendimiento de los modelos de pronóstico lineal estándar (p. ej., un modelo de paseo aleatorio o un modelo AR(1)), para una muestra de empresas estadounidenses de 1975 a 2019. Entrenan los algoritmos de aprendizaje automático para predecir las ganancias anuales con uno, dos y tres años de antelación utilizando 60 características diferentes obtenidas de los estados financieros de las empresas (p. ej., balance general o estados de resultados). Encuentran que la precisión de pronóstico de los modelos de aprendizaje automático fuera de la muestra domina la de los modelos más simples y que la precisión de pronóstico de los modelos de aprendizaje automático es mayor que la de los pronósticos de consenso de los analistas. Otro ejemplo es Gu et al. (2020), quienes comparan el rendimiento predictivo fuera de la muestra de varios modelos de aprendizaje automático. Algoritmos para el exceso de rentabilidad mensual de las acciones entre 1957 y 2016, que abarcan aproximadamente 30 000 acciones. Construyen más de 900 predictores (señales) de exceso de rentabilidad mensual de las acciones basándose en las características de las acciones (p. ej., rentabilidad operativa, capitalización bursátil, etc.), variables macroeconómicas y variables ficticias del sector. Observan que los algoritmos de aprendizaje automático (ML) más complejos tienen un poder predictivo relativo fuera de la muestra significativamente mayor que los más sencillos. También demuestran que las carteras construidas con pronósticos de algoritmos más complejos producen rentabilidades realizadas mucho más cercanas a las previstas que las basadas en algoritmos más sencillos, así como ratios de Sharpe más elevados.

⁸⁴ Este hallazgo, por supuesto, no es específico de la previsión financiera. Por ejemplo, el desafío ImageNet (<https://www.image-net.org/challenges/LSVRC/>) fue un concurso anual para predecir el nombre de un objeto en una imagen mediante algoritmos de aprendizaje automático. El concurso comenzó en 2010 y finalizó en 2017. La tasa de error de los mejores algoritmos se situó por debajo de la de los humanos por primera vez en 2015.

⁸⁵ Por ejemplo, Da Silva y Thesmar (2024) demuestran que las diferencias entre los pronósticos de ML y los pronósticos humanos se deben a que los analistas añaden ruido a los pronósticos racionales, posiblemente debido a limitaciones cognitivas. Coleman et al. (2022) concluyen que las recomendaciones de los analistas robotizados son menos sesgadas que las de los analistas humanos en bancos de inversión, mientras que van Binsbergen et al. (2024) concluyen que los pronósticos de los algoritmos de ML tienen un sesgo menos positivo que las predicciones humanas. Jansen et al. (2024) concluyen que la suscripción algorítmica (para préstamos minoristas) resulta en tasas de impago más bajas, en particular para préstamos en los que es más probable que surjan problemas de agencia para los suscriptores humanos.

⁸⁶ Sin embargo, los algoritmos son escritos por ingenieros de ML que podrían enfrentar conflictos de intereses.

Los pronósticos generados por aprendizaje automático superan a los de los analistas en el 54,5 % de los casos. Sin embargo, también se observa que la incorporación de los pronósticos de los analistas al conjunto de información que utilizan los algoritmos de aprendizaje automático mejora aún más la precisión. El modelo resultante, "centauro analista", supera a los pronósticos de aprendizaje automático en el 54,8 % de los casos.

Como se analiza en el capítulo 2 de este informe, la IA generativa ha emergido recientemente como una poderosa fuerza transformadora para el sector financiero. Los algoritmos de IA generativa responden a indicaciones generando contenido, como texto, imágenes y vídeos. Varios estudios recientes demuestran que estos modelos también pueden utilizarse para predecir las ganancias corporativas y la rentabilidad de las acciones.⁸⁷

Toma de decisiones

Como se explicó en la sección anterior, los algoritmos de aprendizaje automático suelen generar mejores predicciones que las humanas. Estas predicciones pueden utilizarse como base para la toma de decisiones financieras. Por ejemplo, los gestores de fondos pueden entrenar primero algoritmos automáticos para predecir rentabilidades futuras y luego usar estas predicciones para tomar decisiones de inversión.

De manera similar, los asesores de crédito pueden basarse en la evaluación del riesgo crediticio mediante algoritmos de aprendizaje automático para decidir si conceden o no un préstamo a un prestatario. En estos casos, existe una clara división del trabajo: las máquinas evalúan la probabilidad de diversos resultados y los humanos utilizan

Esta evaluación para tomar decisiones.

Sin embargo, esta división se está difuminando por dos razones. En primer lugar, cuando la correspondencia entre las predicciones y las decisiones óptimas es clara, los humanos pueden delegar la decisión a la máquina para ahorrar costos laborales. Por ejemplo, para las solicitudes de préstamos, la aceptación/

El rechazo puede depender simplemente de que el riesgo crediticio esté por encima o por debajo de cierto umbral. Esta decisión también puede codificarse fácilmente en un algoritmo.

En segundo lugar, los algoritmos de aprendizaje automático (ML) también pueden utilizarse para entrenar sistemas a fin de que tomen decisiones autónomas en entornos dinámicos complejos. En particular, los algoritmos de aprendizaje por refuerzo (RL) están diseñados para aprender comportamientos que les permitan alcanzar objetivos específicos con un conocimiento previo mínimo del entorno en el que operan.⁸⁸ Estos algoritmos de autoaprendizaje se han utilizado con éxito, por ejemplo, para jugar al ajedrez y a los videojuegos, logrando victorias contra los mejores jugadores humanos.

⁸⁷ Por ejemplo, Kim et al. (2024) demuestran que ChatGPT puede procesar estados financieros para pronosticar la dirección de los cambios en las ganancias corporativas anuales con una precisión superior a la de los analistas de valores. Curiosamente, al igual que Cao et al. (2024), encuentran evidencia de complementariedad entre los pronósticos generados por ChatGPT y los pronósticos de los analistas de valores, en el sentido de que estos últimos son útiles para predecir el cambio en la dirección de las ganancias corporativas incluso después de controlar los pronósticos de ChatGPT. Lopez-Lira y Tang (2024) utilizan ChatGPT para generar recomendaciones de compra o venta de acciones tras los titulares de noticias del período 2021-2023. Posteriormente, construyen carteras con posiciones largas en acciones con una recomendación alta y posiciones cortas en acciones con una recomendación baja, y observan que esta cartera tiene un buen rendimiento.

⁸⁸ En este caso, el objetivo del algoritmo es aprender a tomar una decisión para lograr un objetivo específico (por ejemplo, maximizar la utilidad terminal promedio del valor de liquidación de una cartera o ganar un juego) con un conocimiento inicial mínimo del entorno. Véase Charpentier et al. (2020) para una presentación del aprendizaje por refuerzo y sus aplicaciones en economía.

En este caso, los humanos siguen siendo importantes para seleccionar y diseñar algoritmos de autoaprendizaje. En particular, la capacidad de estos algoritmos para alcanzar objetivos (p. ej., establecer el precio en línea de un producto para maximizar las ganancias promedio) depende de la retroalimentación que se le proporciona (p. ej., el número de ventas o el margen por venta) y del tipo de variables de estado que el algoritmo puede utilizar para condicionar su decisión en cada momento (¿Precio final?).

¿Historial completo de precios?). Estas son variables de elección para los diseñadores de los algoritmos.

Consideremos un problema de cartera dinámica con un activo de riesgo y uno sin riesgo. Las herramientas de optimización dinámica permiten determinar analítica o numéricamente la asignación óptima de la cartera en cada fecha de reequilibrio. Sin embargo, este enfoque requiere el conocimiento de los parámetros relevantes del modelo y de los supuestos sobre la distribución subyacente de la rentabilidad del activo de riesgo. En este contexto, un algoritmo de autoaprendizaje puede aprender a asignar capital al activo de riesgo sin conocer estas distribuciones, mediante experimentación.⁸⁹

El algoritmo experimenta inicialmente con diversas asignaciones posibles del activo de riesgo en diferentes estados (valor actual de la cartera, rentabilidades pasadas del activo de riesgo, etc.) para evaluar la utilidad promedio asociada a cada asignación en cada estado. Con el tiempo, el algoritmo reduce la frecuencia de la experimentación y selecciona cada vez más, en un estado dado, la asignación que genera la mayor utilidad promedio según su evaluación (la «acción voraz»). Intuitivamente, esto se debe a que, con el tiempo, se espera que el algoritmo haya aprendido la asignación óptima para cada estado.

Existen muchas otras aplicaciones en el contexto de la negociación de valores. Por ejemplo, los algoritmos de autoaprendizaje pueden utilizarse para diseñar estrategias óptimas de cobertura o de ejecución para órdenes grandes, o para la creación de mercado.

3.1.3 Menores costos de adquisición de información

Los algoritmos de aprendizaje automático permiten a los agentes explotar una gran cantidad de datos para generar predicciones más precisas y automatizar decisiones. Sin embargo, el entrenamiento y el uso de estos algoritmos requieren una gran cantidad de cálculos. Los chips más potentes pueden procesar más cálculos por unidad de tiempo y, por lo tanto, reducir el tiempo de entrenamiento de los algoritmos de aprendizaje automático, manteniendo constante su complejidad.⁹⁰ Por lo tanto, la innovación en el diseño de chips (como las GPU) ha sido un tercer factor clave del auge de la IA en el sector financiero y otros sectores. A su vez, este auge ha generado una fuerte demanda de chips informáticos (véase el capítulo 2).

⁸⁹ Véase Barberis y Jin (2023) como ejemplo.

⁹⁰ Véase Cao et al. (2020) para cobertura y Hafsi y Vittori (2024) para ejecución óptima.


La potencia de cálculo de un chip se expresa en operaciones de punto flotante por segundo (FLOPS). Una operación de punto flotante se refiere a un único cálculo realizado con números de punto flotante (números con coma decimal, expresados en notación científica). La GPU NVIDIA A100 Tensor Core puede realizar 312,1012 FLOPS.

Estas innovaciones también han mejorado significativamente el rendimiento de los chips por dólar, es decir, el costo de la potencia informática ha disminuido con el tiempo (Figura 18).⁹² Manteniendo constante la inversión en potencia informática, los participantes en los mercados financieros ahora pueden obtener señales más precisas mediante el uso de algoritmos de aprendizaje automático (ML) más complejos.⁹³ En otras palabras, la disminución de los costos informáticos combinada con el progreso en IA y la abundancia de datos ha reducido el costo de producir información financiera.

81

FIGURA 18 COSTO DE UN SOLO PROCESADOR DE PRECISIÓN Y EL COSTO DE CAPACITACIÓN NOTABLE
MODELOS DE IA

Dólares estadounidenses de 2023 ajustados a la inflación por cada operación de punto flotante adicional; millones de dólares ajustados a la inflación
2023 dólares estadounidenses (escala derecha)



Fuente: FMI (2024).

Esta disminución en el costo de la información es potencialmente un beneficio importante de la adopción de IA por parte de la industria financiera para los consumidores de servicios financieros. El rol de la industria financiera es “producir, negociar y liquidar contratos financieros”.⁹⁴ Estos contratos se utilizan para compartir riesgos o transferir recursos entre agentes (p. ej., de hogares a empresas). Para proporcionar estos servicios, los intermediarios financieros (bancos, corredores, administradores de activos, etc.) cobran tarifas para cubrir sus costos, incluidos los costos de producción de información. Por ejemplo, los bancos o los fondos de capital privado deben producir información para filtrar y monitorear los proyectos de inversión a los que se asignan los ahorros de los hogares. De manera similar, los corredores y distribuidores deben producir información para garantizar que los inversores finales negocien contratos financieros a precios justos en los mercados secundarios, o los administradores de activos deben producir información para construir carteras eficientes y encontrar formas de ejecutar sus órdenes al menor costo.

Inteligencia Artificial

92 Véase también Nordhaus (2021).

93 Sin embargo, la cantidad total invertida para desarrollar herramientas de IA está aumentando a medida que los modelos se vuelven más complejos y las innovaciones razas (ver Sección 3.3.2 para una discusión).

94 Phillippon (2015).

En principio, la reducción de los costos de producción de información debería reducir los costos de intermediación que pagan los consumidores de servicios financieros y beneficiarlos. Sin embargo, esto no es una conclusión inevitable. Phillipon (2015) concluye que el costo de la intermediación financiera en Estados Unidos se mantuvo estable en el 2% (es decir, 2 centavos por dólar de activos financieros intermediados) entre 1886 y 2012. Esto resulta desconcertante, ya que, durante este período, se produjeron mejoras considerables en las tecnologías de la información que el sector financiero ha aprovechado rápidamente.⁹⁵ Por lo tanto, debemos ser cautelosos de que las reducciones en los costos de producción de información no se trasladen plenamente a los consumidores de servicios financieros.

Una posible razón es que los intermediarios financieros tienen poder de mercado. Si las herramientas de IA aumentan, o al menos no reducen, su poder de mercado, los consumidores de servicios financieros no se beneficiarán plenamente de la reducción de los costes de producción de información que conlleva (véase la Sección 3.3.3).

Otra razón es que las mejoras en las tecnologías de la información pueden generar asimetrías informativas entre quienes utilizan la tecnología más avanzada y quienes no (véase la Sección 3.3.2). A su vez, las asimetrías informativas aumentan los costes de selección adversa (pérdidas que sufren las partes menos informadas en sus relaciones con las partes más informadas). En este caso, los consumidores de servicios financieros se beneficiarán menos de las reducciones en los costes de intermediación.

debido a los avances en la tecnología de la información.⁹⁶ Esta posibilidad sugiere que la inversión en tecnologías de la información (p. ej., datos y herramientas de procesamiento de datos) puede ser excesiva en relación con el nivel socialmente óptimo. De hecho, al invertir en estas tecnologías, sus usuarios negocian sus beneficios y costos privados, sin internalizar los costos de selección adversa para otros participantes del mercado. Además, los intermediarios podrían optar por invertir en tecnologías de la información solo para evitar pagar los costos de selección adversa, aunque su inversión no ayude per se a hacer que la intermediación sea más eficiente.⁹⁷ Esto es similar a la lógica de una carrera armamentista donde la carrera es socialmente inútil ya que la sociedad estaría mejor si pudiera evitarse en primer lugar. En cualquier caso, la inversión en tecnologías de la información es excesiva desde el punto de vista de la sociedad (es decir, se podría producir una mayor cantidad de intermediación financiera a un menor costo).

Una última razón es que los intermediarios financieros producen diversos tipos de información, y no todos tienen el mismo valor para la sociedad. Por ejemplo, aprovechar las nuevas tecnologías de la información para pronosticar el valor creado por las startups que trabajan en proyectos innovadores permite a los intermediarios asignar capital de forma más eficiente a los proyectos que generan el mayor valor social. En contraste, el valor social del uso de las nuevas tecnologías de la información...

⁹⁵ Por ejemplo, en 1867 se instalaron teletipos en el piso de la Bolsa de Valores de Nueva York y en 1878 teléfonos ("1889: El telégrafo aumenta la velocidad de las operaciones", Wall Street Journal, 10 de julio de 2014).

⁹⁶ Por ejemplo, supongamos que los avances en las tecnologías de la información reducen el costo real de la intermediación de 2 centavos a 1,5 centavos por dólar intermediado, a la vez que aumentan los costos de selección adversa en la negociación de valores en 0,3 centavos. Dado que estos costos se trasladarán finalmente a los consumidores de servicios financieros, la reducción neta de los costos para estos consumidores será de solo 0,2 centavos y no de 0,5 centavos. Por lo tanto, el aumento total de la demanda de servicios financieros y las ganancias asociadas (por ejemplo, la distribución del riesgo) serán menores.

⁹⁷ Véase Glode et al. (2012), Biais et al. (2015), o Pagnotta y Philippon (2018) para un análisis formal.

Reaccionar con mayor rapidez a los anuncios de noticias, como hacen algunas firmas de trading por cuenta propia, es menos evidente. Por lo tanto, aunque los costos de la información disminuyen, los beneficios sociales de señales más precisas podrían depender del tipo de información que se produzca (véase la Sección 3.3.1).

83

3.2 IMPLICACIONES PARA LA INDUSTRIA DE VALORES

En esta sección, analizamos cómo los cambios tecnológicos descritos en la sección anterior afectan (i) la negociación de valores, (ii) la gestión de activos y (iii) la gestión de patrimonio.

3.2.1 Comercio impulsado por IA

El uso de algoritmos de fijación de precios en los mercados de consumo (p. ej., viajes o alojamiento) es un fenómeno relativamente reciente. En cambio, en los mercados financieros, los operadores llevan al menos 20 años utilizando algoritmos para implementar diversas estrategias de trading. El catalizador fue la adopción por parte de las plataformas de trading de interfaces de programación de aplicaciones (API), conjuntos de reglas y herramientas que permiten la comunicación entre diferentes aplicaciones de software. Las API permiten que los algoritmos de los operadores interactúen directamente con los sistemas operativos de las bolsas, sin necesidad de intervención humana.

Los operadores de valores han desarrollado algoritmos para automatizar las estrategias comerciales estándar. Estos pueden clasificarse en cuatro grandes categorías:⁹⁸

1. Creación de mercado. Los creadores de mercado son intermediarios (operadores) que publican cotizaciones de compra y venta para que los inversores puedan comprar o vender valores sin demora. Anteriormente, las cotizaciones eran publicadas y gestionadas manualmente por personas. Con el tiempo, este proceso se ha automatizado cada vez más mediante algoritmos. En particular, empresas de creación de mercado de alta frecuencia como Citadel Securities, Jane Street y Virtu utilizan algoritmos para publicar cotizaciones en diversos mercados y ajustarlas rápidamente en función de las condiciones cambiantes del mercado o los niveles de inventario.
2. Arbitraje. Los arbitrajistas explotan las discrepancias en los precios entre valores relacionados. Un ejemplo es cuando un mismo valor puede comprarse y venderse casi instantáneamente en diferentes mercados con beneficios. Por ejemplo, los futuros E-mini del S&P 500 y los ETF SPY del S&P 500 son funcionalmente equivalentes, ya que ambos permiten a los inversores operar con una cesta de acciones correspondiente al índice S&P 500. Sin embargo, cuando llega nueva información, las cotizaciones de estos valores no se ajustan simultáneamente, lo que a veces crea breves oportunidades de arbitraje que duran solo unos pocos milisegundos.⁹⁹ Otro ejemplo son las acciones que se negocian en múltiples plataformas de negociación, como es común en Estados Unidos y Europa. En tales casos,

⁹⁸ Véase el capítulo 9 en Foucault et al. (2024).

⁹⁹ Véase Budish et al. (2015).

Las cotizaciones de las mismas acciones en diferentes plataformas pueden diferir temporalmente, lo que permite a los inversores rápidos comprar una acción en una plataforma y revenderla inmediatamente a un precio más alto en otra.¹⁰⁰ El trading algorítmico proporciona una forma de reaccionar rápidamente a dichas oportunidades, explotándolas antes que otros lo hagan o antes de que se ajusten las cotizaciones.

3. Operaciones direccionales. Los operadores direccionales compran o venden valores basándose en información privada que aún no se refleja en los precios. Por ejemplo, los gestores de fondos pueden combinar datos alternativos y algoritmos de aprendizaje automático para generar señales de compra o venta de una acción (véanse las secciones 3.1 y 3.2.2). También pueden utilizar algoritmos para acceder rápidamente al texto de las presentaciones regulatorias de nuevas empresas cuando se publican en el sitio web de la Comisión de Bolsa y Valores de EE. UU. (SEC) (EDGAR) o durante los anuncios del Comité Federal de Mercado Abierto (FOMC). Estos algoritmos procesan el texto mediante técnicas de procesamiento del lenguaje natural para extraer señales sobre los beneficios futuros y generar órdenes de compra o venta basándose en estas señales (véase el capítulo 4).
4. Minimización de los costes de negociación. Los corredores y las mesas de negociación de inversores institucionales emplean diversas estrategias para minimizar los costes de negociación. Por ejemplo, un operador que desee comprar un millón de acciones puede ejecutar la orden gradualmente para reducir su impacto en los precios y evitar pagar un margen excesivo respecto al valor razonable de la acción. En este caso, el operador debe determinar la tasa de ejecución (cómo fragmentar la orden a lo largo del tiempo), los centros de negociación a los que se dirigen las órdenes y el tipo de órdenes utilizadas (límite o mercado), todo ello con el objetivo de minimizar el impacto en el precio medio. Esto presenta un complejo problema de optimización dinámica, que a menudo requiere ajustes frecuentes de la estrategia de ejecución de órdenes a medida que evolucionan las condiciones del mercado. Cada vez más, los traders confían en "algoritmos de ejecución" para implementar y refinar estas estrategias en tiempo real.¹⁰¹

En resumen, los algoritmos utilizados en los mercados financieros cumplen diversos propósitos y son utilizados por distintos tipos de agentes (por ejemplo, corredores y fondos para minimizar los costos de ejecución, firmas de trading por cuenta propia para la creación de mercado y gestores de fondos activos para explotar información privada). Además, algunos algoritmos deben acceder y procesar la información con extrema rapidez (operadores de alta frecuencia), mientras que otros operan a frecuencias más bajas.


Si bien el uso de algoritmos para la negociación de valores no es nuevo, se han producido avances significativos en los últimos años. En primer lugar, como se muestra en la Figura 19, su uso está en aumento en todas las clases de activos, incluyendo aquellos que tradicionalmente se negociaban extrabursátilmente (como bonos soberanos y corporativos o divisas). Esta evolución es consecuencia del desarrollo de plataformas de negociación electrónica en estos mercados.¹⁰²

¹⁰⁰ Véase Wah (2016).

¹⁰¹ Véase Frazzini et al. (2018) y Beason y Wahal (2020).

¹⁰² Véase el Capítulo 4 en Duffie et al. (2022) para una descripción de esta evolución.

FIGURA 19 CUOTA DE MERCADO DEL COMERCIO ALGORÍTMICO POR CLASE DE ACTIVO Y REGIÓN




Fuente: Goldman Sachs (2018).

En segundo lugar, los algoritmos de trading dependen cada vez más de herramientas de IA. Por ejemplo, el número de patentes relacionadas con el trading algorítmico y de alta frecuencia que mencionan la IA está en aumento (Figura 20). Una razón es que, como se explicó anteriormente, los algoritmos de aprendizaje automático son herramientas eficaces para mejorar la precisión de los pronósticos sobre cambios futuros en precios, liquidez o flujo de órdenes (véase la Sección 3.1.2).¹⁰³

FIGURA 20 PATENTES RELACIONADAS CON EL COMERCIO ALGORÍTMICO/DE ALTA FRECUENCIA

Número de patentes; porcentaje de patentes



Fuente: FMI (2024).

¹⁰³ Por ejemplo, Easley et al. (2021) utilizan un algoritmo de bosque aleatorio para predecir la dirección de los cambios en los diferenciales entre oferta y demanda o la volatilidad realizada en diversos mercados de futuros mediante características basadas en datos de mercado. Argumentan que la construcción de estos modelos predictivos es valiosa para los algoritmos de ejecución, ya que les permiten ajustar su tasa de negociación a los cambios esperados en las condiciones del mercado (p. ej., aumentar la tasa de ejecución cuando se espera que los diferenciales entre oferta y demanda o la volatilidad aumenten).

Una encuesta a empresas neerlandesas de trading por cuenta propia, realizada por la Autoridad Holandesa de Mercados Financieros (Autoriteit Financiële Markten o AFM), indica que entre el 80 % y el 100 % de los algoritmos de los encuestados se basan en el aprendizaje automático.¹⁰⁴ Aún no está claro si estos algoritmos se utilizan únicamente para generar pronósticos para algoritmos con reglas de trading predefinidas (p. ej., «Si se espera que el precio de la acción A aumente en los próximos 5 minutos, compre todas las acciones disponibles al mejor precio») o si algunos están diseñados para aprender estrategias de trading de forma independiente mediante aprendizaje por refuerzo (véase la sección 3.1.2). Sin embargo, algunos bancos ya utilizan algoritmos de aprendizaje por refuerzo para optimizar la ejecución de órdenes grandes.¹⁰⁵

Una pregunta importante es cómo el trading algorítmico afecta la liquidez y el descubrimiento de precios en los mercados de valores. En general, estudios académicos han demostrado que el trading algorítmico se asocia con una mejora en el descubrimiento de precios (por ejemplo, los precios se acercan más a un paseo aleatorio, lo que significa que incorporan mejor la información disponible). En cambio, el efecto del trading algorítmico en los costes de negociación (una dimensión de los costes de intermediación) es menos claro.¹⁰⁶

Una razón es que un acceso más rápido a la información, gracias a la automatización de las operaciones, puede reducir o aumentar la exposición de los creadores de mercado a la selección adversa. Consideremos la llegada de noticias sobre una acción. Los creadores de mercado corren el riesgo de operar con cotizaciones obsoletas y, por lo tanto, perder dinero si no actualizan sus precios rápidamente. Esto a veces se denomina «riesgo de ser atacado» y constituye un tipo de riesgo de selección adversa.

Un procesamiento más rápido de la información y un acceso más ágil a las plataformas de negociación tienen un efecto ambiguo en el riesgo de ser víctima de un fraude. Por un lado, permiten a los operadores cancelar sus cotizaciones con mayor rapidez, mitigando así su exposición a este riesgo. Por otro lado, permiten a los operadores eliminar las cotizaciones obsoletas de otros operadores con mayor rapidez, lo que aumenta la exposición de estos al riesgo de ser víctima de un fraude. Si bien el efecto neto es teóricamente ambiguo, algunos estudios empíricos concluyen que el segundo efecto predomina: un acceso más rápido a la información y las respuestas a esta aumentan los costos de selección adversa.¹⁰⁷

Esto no implica que el trading algorítmico resulte necesariamente en mayores diferenciales entre oferta y demanda (costos de negociación para los inversores finales). De hecho, los estudios generalmente concluyen que el trading algorítmico ha reducido los costos totales de negociación.¹⁰⁸ Lo que sí significa es que esta reducción de costos es menor de lo que podría ser sin los costos de selección adversa.

104 Véase AFM (2023).

105 Un ejemplo es AIDEN, un algoritmo de refuerzo desarrollado por el Royal Bank of Canada (véase <https://www.rbccm.com/en/experiencia/comercio-electronico/ai-trading.page>.)

106 Véase el Capítulo 4 en Duffie et al. (2022) y el Capítulo 9 en Foucault et al. (2024) para análisis detallados de los hallazgos empíricos y teóricos sobre estos temas.

107 Véase, por ejemplo, Shkilko y Sokolov (2020), Aquilina et al. (2024) y Foucault et al. (2017).

108 Véase Hendershott et al. (2011), por ejemplo.

Una salvedad es que los hallazgos empíricos sobre los efectos del trading algorítmico en los mercados financieros se han recopilado, en gran medida, durante un período en el que los algoritmos de trading aún no incorporaban herramientas de IA. En consecuencia, por el momento, se sabe poco sobre el impacto de los algoritmos de aprendizaje automático en la liquidez, el descubrimiento de precios o la estabilidad del mercado. Se necesita más investigación sobre este tema.

87

3.2.2 Gestión de activos impulsada por IA

Los gestores de activos desempeñan un papel importante. Ayudan a los inversores a diversificar sus inversiones en valores a bajo coste. La negociación algorítmica les permite reducir aún más estos costes, ayudándoles a ejecutar sus órdenes con un bajo impacto en los precios (Sección 3.2.1). Además, los gestores de fondos activos generan información sobre los flujos de caja futuros de los valores para identificar valores infravalorados o sobrevalorados y crear carteras de valores que aprovechen estas ineficiencias en la fijación de precios. De este modo, aumentan la eficiencia informativa de los mercados financieros y la información sobre los precios de los activos.

Los gestores de fondos activos recurren cada vez más a datos alternativos (Sección 3.1.1) y algoritmos de aprendizaje automático (ML) (Sección 3.1.2) para generar información. Por ejemplo, un informe de 2017 de JP Morgan señala que «en la búsqueda de [...] alfa, los gestores de fondos adoptan cada vez más estrategias cuantitativas. [...] Está surgiendo una nueva fuente de ventaja competitiva con la disponibilidad de fuentes de datos alternativos, así como con la aplicación de nuevas técnicas cuantitativas de aprendizaje automático para analizar estos datos». 109 Además, las herramientas de IA pueden utilizarse para la generación de ideas y la construcción de carteras. 110

Una manifestación de esta evolución es el auge de los fondos cuantitativos (AQR, Citadel, Renaissance Technologies, Two Sigma, DE Shaw, etc.), es decir, fondos que se basan en el análisis matemático y estadístico de grandes cantidades de datos para generar sus señales comerciales y construir sus carteras.¹¹¹ Por ejemplo, en una encuesta realizada por Mercer a 150 empleados (directores de tecnología o miembros de equipos de inversión) en empresas de gestión de activos, el 48 % de los encuestados indicó que su institución utiliza modelos de aprendizaje automático y el 26 % informó utilizar IA generativa.¹¹² Otra encuesta de BarclayHedge encontró que más del 50 % de los fondos de cobertura

Investigación

109 Véase también "Cuando Silicon Valley llegó a Wall Street", Financial Times, 27 de octubre de 2017; "En BlackRock, las máquinas se alzan sobre los gerentes para elegir acciones", The New York Times, 28 de marzo de 2017; "DE Shaw: dentro del fondo de cobertura 'Silicon Valley' de Manhattan", Financial Times, 26 de marzo de 2024; "Los selectores de acciones recurren al big data para detener la caída del mercado", Financial Times, 11 de febrero de 2020.

110 Por ejemplo, Cong et al. (2022) utilizan un algoritmo de aprendizaje por refuerzo (denominado «AlphaPortfolio») para la asignación de carteras. El algoritmo está entrenado para seleccionar asignaciones con ratios de Sharpe elevados y lograr un alto rendimiento fuera de la muestra. Véase también Bryzgalova et al. (2020) y Kozak et al. (2020).

111 Abis (2022) concluye que los fondos cuantitativos representaron el 18,6% de todos los fondos de renta variable activos de Estados Unidos en 2017, frente al 6,1% en 2000. Los fondos cuantitativos dependen de equipos de investigación para descubrir predictores de rentabilidades futuras. Estos estiman diversos modelos predictivos de rentabilidades futuras utilizando una gran cantidad de datos y solo invierten en aquellos cuyo rendimiento predictivo es suficientemente bueno. Véase el capítulo 9 de Nayang (2013) para una descripción del papel de los equipos de investigación en los fondos cuantitativos.

112 Véase Mercer (2024).

Los fondos encuestados utilizan el aprendizaje automático para desarrollar sus estrategias, especialmente en la construcción de carteras y la generación de ideas. Además, algunos estudios evidencian la adopción de la IA por parte de los gestores de fondos, como lo demuestra el aumento de las ofertas de empleo que requieren habilidades en IA o la correlación entre los cambios en sus carteras y las señales generadas por la IA generativa.¹¹³

Esta evolución plantea varias preguntas. ¿Cuáles son los efectos de la adopción de la IA en el rendimiento de los gestores de fondos? ¿Es inevitable el auge de los fondos cuantitativos y el declive de los fondos discrecionales (aquellos que se basan en el criterio humano y la información blanda)? ¿Cómo afecta esta tendencia a la liquidez del mercado (los costes de negociación para los inversores en general) y a la información que ofrecen los precios de los valores sobre los fundamentales (flujos de caja futuros)?

La investigación sobre estas cuestiones es apenas incipiente. En un posible escenario,¹¹⁴ el acceso a datos cada vez más diversos y las mejoras en las herramientas de procesamiento de datos permitirán a los fondos cuantitativos generar señales cada vez más precisas a corto plazo. En igualdad de condiciones, esto mejorará su rendimiento promedio, de modo que los inversores finales transferirán su capital de los fondos discrecionales a los fondos cuantitativos. Sin embargo, a medida que el capital asignado a los fondos cuantitativos aumenta y sus señales se vuelven más informativas, los precios de los valores deberían reflejar su información privada con mayor rapidez. Este efecto implica que el auge de los fondos cuantitativos podría eventualmente estancarse.

Una preocupación frecuente es que la adopción de algoritmos de aprendizaje automático por parte de los fondos cuantitativos podría llevarlos a operar con base en señales más correlacionadas, lo que podría aumentar el riesgo de un reequilibrio coordinado de la cartera y espirales de precios que se retroalimentan, similares a las observadas durante la crisis cuantitativa de agosto de 2007.¹¹⁵ Sin embargo, actualmente no hay evidencia de que la IA y los datos alternativos aumenten los puntos en común en las señales de trading utilizadas por los fondos cuantitativos. De hecho, la diversidad de datos alternativos debería ayudar a diversificar las fuentes de señales de las que dependen estos fondos, lo que podría hacer que sus tenencias estén menos sincronizadas.

Otra pregunta relacionada es cómo afectará el auge de los datos alternativos a los gestores de fondos tradicionales, aquellos que dependen de métodos convencionales para generar información (profundo conocimiento institucional y experiencia en el sector, formación, redes de contactos, etc.). Los datos alternativos proporcionan nuevas señales a los gestores de fondos activos. Sin embargo, extraer estas señales requiere inversiones específicas en mano de obra cualificada y tecnología, como la contratación de científicos de datos y la adquisición de hardware para el procesamiento de datos. Los gestores que no realicen estas inversiones podrían experimentar una disminución en su rendimiento debido a la competencia de los fondos cuantitativos.

¹¹³ Zhang (2024) recopila ofertas de empleo de empresas de gestión de activos utilizando datos de Burning Glass y descubre que la proporción de ofertas que requieren habilidades de IA ha aumentado considerablemente desde 2016. De igual forma, Abis y Veldkamp (2024) reportan una tendencia comparable. Sheng et al. (2024) desarrollan una medida de la confianza en la información generada por IA mediante ChatGPT.

Generar señales basadas en las conferencias telefónicas sobre resultados de las empresas. Demuestran que esta medida explica los cambios en las inversiones de los fondos de cobertura, incluso después de controlar otras fuentes de información.

¹¹⁴ Véase Dugast y Foucault (2024).

¹¹⁵ Véase Khandani y Lo (2011).

Si este es el caso o no podría depender de si la información producida por los gestores de fondos tradicionales y la derivada de datos alternativos son "sustitutos" (lo que significa que pertenecen a los mismos componentes de los flujos de efectivo de los activos futuros) o "complementos" (lo que significa que pertenecen a diferentes componentes de esos flujos de efectivo).

Por ejemplo, muchos tipos de conjuntos de datos alternativos, como datos de puntos de venta o reseñas de productos de consumo, son útiles para pronosticar la demanda a corto plazo en una industria determinada.¹¹⁶ Estos conjuntos de datos pueden predecir la demanda a corto plazo de una empresa o un sector industrial. Si la capacidad de los gestores de fondos tradicionales para seleccionar acciones también se basa en un conocimiento superior de la demanda de productos, la disponibilidad de datos alternativos debería reducir su ventaja informativa.¹¹⁷

En cambio, los datos alternativos son menos útiles para evaluar las perspectivas de nuevos productos o nuevas tecnologías de producción. Por ejemplo, es difícil evaluar las perspectivas de los aviones propulsados por hidrógeno porque esta tecnología aún no se ha utilizado a gran escala y aún se encuentra en desarrollo.¹¹⁸ Por lo tanto, evaluar las inversiones en I+D de los fabricantes de aerolíneas en este ámbito requiere conocimientos específicos del sector. Si la capacidad de los gestores de fondos tradicionales para seleccionar acciones depende, al menos en parte, de este tipo de conocimiento único, deberían verse menos afectados por la disponibilidad de datos alternativos; incluso podrían beneficiarse. De hecho, al hacer que los precios sean más informativos, los fondos cuantitativos que operan con datos alternativos podrían reducir la incertidumbre a la que se enfrentan los inversores que operan con información no disponible en dicho mercado.¹¹⁹ En teoría, esto puede aumentar su rendimiento.¹²⁰

Por esta razón, es importante identificar situaciones en las que el criterio humano no puede ser fácilmente reemplazado por máquinas y datos para realizar predicciones. Estos conocimientos podrían allanar el camino para fondos híbridos que se basan en una combinación de enfoques cuantitativos y discrecionales.¹²⁰ Si el juicio humano es útil, esto ayudaría a diversificar la forma en que los gestores de fondos activos producen información.

El capital riesgo (CR) es otro ámbito donde la IA se utiliza para fundamentar las decisiones de inversión. Por ejemplo, Bonelli (2024) documenta un aumento en la proporción de fondos de CR que emplean analistas de datos para construir infraestructuras de datos y diseñar algoritmos para la selección de proyectos de inversión entre 2000 y 2020. El autor también demuestra que los fondos de CR que emplean analistas de datos («fondos basados en datos») son más eficaces en la selección de nuevas empresas emergentes, como lo demuestra el hecho de que estas tienen mayor probabilidad de obtener financiación en etapas posteriores.

¹¹⁶ Por ejemplo, Jin (2021) muestra que el tono lingüístico de las reseñas de productos de consumo en Amazon.com transmite información sobre las ventas y ganancias trimestrales de las empresas. Tang (2018) concluye que la información de productos generada por terceros en Twitter, agregada a nivel de empresa, predice las ventas a nivel de empresa.

¹¹⁷ Bonelli y Foucault (2024) aportan evidencia que respalda el escenario de los «sustitutos». Específicamente, documentan una disminución del rendimiento de los gestores de fondos que recurren a fuentes tradicionales de especialización, como la especialización industrial o el conocimiento geográfico, en el contexto de las existencias de minoristas cubiertas por los datos alternativos considerados en su estudio (recuento de automóviles en los aparcamientos de los minoristas estadounidenses a partir de imágenes satelitales).

¹¹⁸ Véase "Airbus pospone sus planes de volar aviones de hidrógeno en 2035", Financial Times, 7 de febrero de 2025.

¹¹⁹ Véase Goldstein y Yang (2015).

¹²⁰ De hecho, algunos fondos parecen estar ya adoptando este enfoque "cuantitativo"; véase "DE Shaw: inside Manhattan's 'Silicon Valley' hedge fund", Financial Times, 26 de marzo de 2019.

rondas de financiación en comparación con las seleccionadas por otros fondos. Sin embargo, esta ventaja solo se aplica a proyectos con descripciones de negocio similares a las de proyectos anteriores. Intuitivamente, cuando este no es el caso, los modelos predictivos utilizados por los fondos basados en datos carecen de datos pasados para hacer predicciones precisas.

90


Es probable que el impacto de la IA en el rendimiento de los fondos de capital riesgo difiera de su efecto en los gestores de fondos activos. En este último caso, la teoría económica predice que las rentas informativas obtenidas por los fondos que utilizan herramientas de IA deberían, al menos parcialmente, disiparse a través del proceso de negociación. Además, estas rentas se obtienen a expensas de los participantes menos informados y contribuyen a la iliquidez del mercado al aumentar los costes de selección adversa para estos últimos (véase la Sección 3.3.2 para más información). Por el contrario, el uso de herramientas de IA por parte de los fondos de capital riesgo debería mejorar la selección de proyectos de inversión. Esta mejora, a su vez, debería resultar en una asignación más eficiente del capital y una mayor creación de valor a través del proceso de inversión.

INTELIGENCIA

3.2.3 Asesoramiento financiero impulsado por IA

Otro ámbito significativamente impactado por la automatización del proceso de inversión es la industria de gestión de patrimonio, que ofrece una gama de servicios de inversión a particulares. Tradicionalmente, los asesores financieros se centraban en atender a inversores adinerados. Sin embargo, la automatización de los procesos de inversión y negociación ha reducido el coste de la atención a los clientes y ha impulsado la aparición de los robo-advisors (véase la Figura 21), que ofrecen y ejecutan asesoramiento financiero mediante algoritmos automatizados en plataformas digitales.

FIGURA 21 ACTIVOS BAJO GESTIÓN POR ROBO-ADVISORS



Fuente: Statista Market Insights

Inicialmente, los robo-advisors, como Betterment (lanzado en 2010) y Wealthfront (lanzado en 2011) en Estados Unidos, o MoneyFarm en el Reino Unido, operaban como empresas fintech independientes. Rápidamente les siguieron corredores y bancos consolidados, como Vanguard, Bank of America, Charles Schwab y E*Trade.

Los robo-advisors se basan en algoritmos para ofrecer recomendaciones de cartera personalizadas a los inversores y, en algunos casos, ejecutan operaciones automáticamente en función de las elecciones de los inversores. Estas recomendaciones se generan tras recopilar información sobre los objetivos del inversor, su horizonte de inversión, su tolerancia al riesgo, sus ahorros y otros factores relevantes. Los robo-advisors también pueden ofrecer servicios adicionales de gestión patrimonial, como la recolección de impuestos de cartera, la previsión del flujo de caja y la planificación de los ingresos para la jubilación.

Los estudios académicos sugieren que el asesoramiento robótico tiene el potencial de brindar beneficios significativos a los inversores.¹²¹ En particular, ofrece asesoramiento financiero sofisticado y de bajo costo a una gran cantidad de inversores minoristas y puede ayudarlos a diversificar mejor sus carteras. Además, puede ayudar a mitigar los conflictos de agencia comúnmente asociados con los asesores humanos y protegerlos contra sesgos de comportamiento (como el efecto de disposición). Sin embargo, una posible preocupación es que las empresas que ofrecen robo-advisors podrían enfrentarse a conflictos de intereses, lo que generaría nuevos problemas de agencia.¹²²

3.3 RIESGO

La revolución del big data (el auge del big data, combinado con los avances en IA y la disminución de los costos de computación) reduce el costo de producir información financiera y aumenta la precisión de las previsiones financieras (Sección 3.3.1). Por lo tanto, tiene el potencial de reducir los costos de intermediación y aumentar los beneficios que la sociedad obtiene de una información financiera más precisa (por ejemplo, al canalizar el capital hacia usos más productivos). De ser así, los consumidores de servicios financieros (hogares, empresas y gobiernos) aumentarán su demanda y se beneficiarán.

Sin embargo, varios obstáculos pueden impedir que la sociedad aproveche plenamente estos avances. En primer lugar, para lograrlo, los intermediarios financieros deben producir el tipo de información más valiosa para la sociedad. En la Sección 3.3.1, argumentamos que esto no necesariamente debe ser así. En segundo lugar, las nuevas tecnologías de la información no deberían permitir que los intermediarios financieros aumenten sus ingresos. Estos, en última instancia, incrementan el costo de la intermediación para los usuarios de servicios financieros y pueden resultar en costos de peso muerto para la sociedad. Los ingresos de los intermediarios podrían ser informativos si los nuevos datos y las nuevas técnicas de procesamiento de datos se amplifican.

¹²¹ D'Acunto et al. (2019) estudian la introducción de un asesor robótico para la gestión patrimonial en India. Observan que los inversores que adoptan el asesor robótico aumentan la diversificación de sus carteras y alcanzan ratios de Sharpe significativamente más altos. Además, estos inversores se vuelven menos susceptibles a sesgos de comportamiento, como el efecto de disposición, en comparación con quienes no lo adoptan. Rossi y Utkus (2024) analizan datos del mayor asesor robótico estadounidense, "Personal Advisor Service" de Vanguard. De igual manera, observan que el asesoramiento robótico anima a los inversores a mantener carteras más diversificadas, en particular al aumentar su participación en fondos indexados. Véase también Philippon (2020) para un análisis teórico de los beneficios sociales de los asesores robóticos.

¹²² Véase SEC (2023).

Asimetrías de información (Sección 3.3.2), o podrían derivar de un mayor poder de mercado (Sección 3.3.3). Una última preocupación, analizada en la Sección 3.3.4, es que mitigar estos riesgos puede ser difícil debido a la naturaleza de "caja negra" de los algoritmos de aprendizaje automático. En particular, su complejidad dificulta que los reguladores detecten posibles usos indebidos.

3.3.1 ¿La mala información desplaza a la buena?

Una función importante de los mercados de valores es ofrecer mecanismos para descubrir el valor de los activos, lo que permite a los inversores negociar valores a precios justos. Además, la determinación eficiente de precios permite a los responsables de la toma de decisiones (por ejemplo, los gestores de empresas o los bancos centrales) utilizar la información que proporcionan los precios de los valores para sus decisiones (por ejemplo, inversiones corporativas o política monetaria), además de su propia información privada. Los precios de los activos informativos también ayudan a alinear mejor los incentivos de los gestores con la creación de valor para los accionistas de las empresas.¹²³ A través de estos canales, unos precios de los valores más informativos pueden impulsar el crecimiento económico.¹²⁴

Una pregunta importante es, por lo tanto, si la abundancia de datos, la IA y el aumento del poder de procesamiento mejoran la información de los precios de los valores sobre los flujos de efectivo futuros.¹²⁵

Intuitivamente, se podría pensar que esto debería ser así, ya que la combinación de estos factores permite a los inversores obtener señales más precisas a un menor coste (véase la Sección 3.1.3). Por ejemplo, Verrecchia (1982, p. 1427) afirma: «A medida que las mejoras tecnológicas permiten obtener más información al mismo coste, la mayor adquisición de información por parte de los operadores resulta en que los precios revelen más información». La lógica es la siguiente: una disminución del coste de la producción de información impulsa a los inversores a adquirir señales más precisas, lo que les lleva a realizar apuestas más agresivas cuando su estimación del valor de los activos se desvía de los precios de estos. Como resultado, mediante el equilibrio del mercado, la información privada de los inversores se agrega a los precios de forma más eficiente y estos se vuelven informativos.

Sin embargo, esta lógica ignora que los intermediarios financieros tienen una capacidad limitada, ya sea en términos de tiempo o de capacidad de procesamiento, para generar información, y deben asignar esta capacidad a diferentes tipos de tareas predictivas. Por ejemplo, deben decidir si se centran más en predecir los flujos de caja a corto plazo o a largo plazo, los factores sistemáticos o idiosincrásicos en los flujos de caja de los activos, o el ruido en los precios de los activos (por ejemplo, la confianza de los inversores) o los fundamentos.

¹²³ Véase Bond et al. (2012) y Goldstein (2023).

¹²⁴ Véase Peress (2014) para un modelo de los vínculos entre la informatividad de los precios y el crecimiento económico.

¹²⁵ Se puede considerar la informatividad del precio de un activo como la distancia entre su precio y su valor fundamental (la suma de sus flujos de caja futuros descontados). Este último se desconoce cuando se observan los precios, lo que dificulta la medición empírica de la informatividad del precio. Existen diversas medidas en la literatura (p. ej., Bai et al., 2016; Weller, 2018).

Al tomar estas decisiones, los intermediarios sopesan los beneficios privados de asignar capacidad informativa adicional a un tipo de información frente a los costos privados de estar menos informados sobre otro. Si bien sus decisiones pueden ser óptimas desde su perspectiva, podrían no coincidir con lo que es óptimo para la sociedad, especialmente porque los intermediarios generalmente no son recompensados por mejorar la información sobre los precios ni, en términos más generales, por el valor social de la información que producen. En consecuencia, tienen pocos incentivos para generar el tipo de información más valiosa para la sociedad.

Consideremos algunos ejemplos. Consideremos primero un fondo cuantitativo (véase la Sección 3.2.2). Los investigadores del fondo (científicos de datos) pueden optar por adquirir diversos conjuntos de datos alternativos para pronosticar mejor las ganancias futuras de las empresas (información fundamental). A su vez, estas predicciones pueden utilizarse para calcular el valor de las empresas, identificar acciones con precios incorrectos y operar con ellas en consecuencia. A medida que el fondo compra acciones infravaloradas y vende acciones sobrevaloradas, gradualmente hace que los precios de estas acciones sean más informativos sobre sus ganancias futuras.

Sin embargo, el gestor del fondo puede utilizar otra estrategia. Al fin y al cabo, si otros inversores operan con información privada, el fondo puede extraer información de los precios de los valores (en términos más generales, datos de mercado) y operar con base en dicha información. ¹²⁶ Por ejemplo, los investigadores del fondo pueden centrarse en estimar el ruido en los precios de los activos (por ejemplo, prediciendo la demanda de inversores desinformados, como los inversores minoristas o los fondos indexados) para estimar mejor los fundamentos o especular sobre futuras fluctuaciones no fundamentales de los precios. ¹²⁷ Este es un uso alternativo de la capacidad del fondo para generar información. A diferencia de la estrategia anterior, esta estrategia no aporta información nueva sobre los precios y, por lo tanto, es menos útil para la sociedad que la primera.

Por supuesto, los fondos pueden usar ambas estrategias, pero se enfrentan a un dilema al elegir qué proporción de su capacidad para producir información debe asignarse a una estrategia. Usar más capacidad para la segunda estrategia significa menos capacidad para la primera y, por lo tanto, menos señales informativas sobre los fundamentales. Investigaciones recientes sugieren que un aumento en la capacidad informativa, debido a los avances en tecnologías de la información como la IA, puede llevar a los gestores de fondos a asignar más de su capacidad a la segunda estrategia (produciendo más información no fundamental). ¹²⁸ Hacerlo es privado óptimo para los gestores de fondos, pero es una oportunidad perdida para que la sociedad obtenga señales más precisas sobre los fundamentales. En este escenario, las mejoras en las tecnologías de la información resultan en un menor aumento en la informatividad de los precios que cuando los gestores de fondos solo producen información fundamental.

¹²⁶ El hecho de que los datos del mercado contengan información es una de las razones por las que los inversores están dispuestos a pagar tarifas elevadas por esos datos. En Estados Unidos, los corredores envían órdenes minoristas a corredores a cambio de pagos («pagos por flujo de órdenes»). Empresas creadoras de mercado como Citadel Securities, Jane Street o Virtu Financial se comprometen a ejecutar estas órdenes a precios iguales o mejores a los publicados en las bolsas. Estos pagos les permiten a estas empresas obtener información a petición de inversores desinformados.

¹²⁸ Véase Farboodi y Veldkamp (2020).

Consideremos ahora un segundo ejemplo. El trading algorítmico aumenta la velocidad con la que se procesan y utilizan nuevos datos para operar. Sin embargo, existe un equilibrio entre velocidad y precisión. Consideremos la llegada de noticias complejas, como un anuncio de política monetaria, una presentación regulatoria (por ejemplo, un formulario 10-K) o una presentación de resultados. Estos eventos proporcionan nuevos datos para predecir los flujos de caja y los precios de las acciones futuras de las empresas.¹²⁹ Son complejos porque pueden implicar textos extensos o interacciones verbales extensas entre diversos participantes, como ejecutivos de la empresa y analistas de valores.¹³⁰

Los algoritmos de aprendizaje automático permiten a los inversores extraer rápidamente señales (p. ej., del sentimiento o el tono del texto) sobre las implicaciones de las noticias para los flujos de caja y los precios futuros. Sin embargo, estas señales tempranas y rápidas son menos precisas que las obtenidas mediante la recopilación y el análisis de datos adicionales. Esto no plantearía un problema, e incluso podría mejorar la información de los precios, si los esfuerzos posteriores para generar información no se vieran afectados por la llegada de la señal temprana. Sin embargo, un aumento en la demanda de señales tempranas, pero imprecisas, tras la publicación de nuevos datos reduce los incentivos de los inversores para procesarlos en mayor profundidad, lo que limita la posibilidad de una mayor precisión. En consecuencia, una reducción en el coste de la extracción rápida de información de nuevos datos puede, en última instancia, perjudicar la información de los precios.¹³¹

Otro ámbito en el que los inversores se enfrentan a disyuntivas de información es la producción de información a corto y largo plazo. Consideremos a los analistas de renta variable. Estos elaboran habitualmente pronósticos de beneficios a corto y largo plazo para las empresas. Estas tareas están relacionadas (ya que los beneficios están correlacionados a lo largo del tiempo), pero son distintas. En particular, los beneficios a largo plazo requieren una comprensión y un análisis más profundos de las decisiones estratégicas de las empresas y sus consecuencias. Al dedicar más esfuerzo a pronosticar las ganancias a corto plazo (por ejemplo, durante los próximos dos años), los analistas pueden obtener una señal más precisa sobre estas ganancias. Sin embargo, esto reduce la capacidad de generar información sobre los flujos de efectivo a largo plazo (por ejemplo, en un horizonte temporal superior a dos años). Por lo tanto, dedicar más esfuerzo a la tarea de generar información a corto plazo tiene un costo sombra: aumenta la dificultad y el costo de pronosticar los flujos de efectivo a largo plazo.¹³²

129 Por ejemplo, Ewertz et al. (2024) desarrollan un algoritmo de aprendizaje automático, FinVoc2Vec, que mide el tono de voz de los gerentes en grabaciones de audio de conferencias telefónicas. Demuestran que el algoritmo puede utilizarse para predecir ganancias y rentabilidades bursátiles. Véase también Baik et al. (2024).

130 Cohen et al. (2020) muestran que la longitud de los informes 10-K ha aumentado drásticamente con el tiempo, de menos de 15 000 palabras en promedio en 1995 a más de 60 000 en 2017.

131 Dugast y Foucault (2018).


132 Dessaint y otros (2024).

El auge de los datos alternativos reduce el coste del esfuerzo para producir información a corto plazo más que el coste para producir información a largo plazo, ya que los conjuntos de datos alternativos suelen ser útiles para predecir las ganancias a corto plazo, pero no las ganancias a largo plazo. Como resultado, la disponibilidad de datos alternativos podría inducir a los analistas a asignar, de forma óptima, más esfuerzo a la producción de información a corto plazo y menos a la de información a largo plazo. De ser así, sus pronósticos a corto plazo deberían ser más precisos, mientras que los de largo plazo deberían ser menos precisos.

95

La Figura 22 proporciona evidencia que respalda esta conjetura. Muestra que, con el tiempo, la precisión («informatividad») de los pronósticos a largo plazo de los analistas de renta variable estadounidenses ha disminuido, mientras que la calidad de sus pronósticos a corto plazo ha mejorado. Además, esta tendencia es más pronunciada en el caso de las acciones de sectores donde los informes de los analistas de renta variable mencionan con mayor frecuencia que han utilizado datos alternativos para elaborar sus pronósticos. Además, observan que la disponibilidad de nuevos datos alternativos reduce la precisión de los pronósticos a largo plazo de los analistas de renta variable, a la vez que mejora la calidad de los de corto plazo.

FIGURA 22 EVOLUCIÓN DE LA PRECISIÓN DE LAS PREVISIONES DE GANANCIAS DE LOS ANALISTAS DE RENTA VARIABLE ESTADOUNIDENSE



Nota: La figura muestra la evolución de una medida ("informatividad") de la precisión de los pronósticos de ganancias a corto plazo (menos de dos años; panel del lado izquierdo) y a largo plazo (más de dos años; panel del lado derecho) de los analistas de acciones estadounidenses desde 1980 hasta 2017. La medida controla los cambios en la variabilidad de las ganancias (incertidumbre) a lo largo del tiempo.

Fuente: Dessaint et al. (2024).

El precio de un activo es el valor descontado de sus flujos de caja futuros esperados. Por lo tanto, un cambio en la calidad de las expectativas de los inversores en diversos horizontes afecta la información que los precios de los activos proporcionan sobre los flujos de caja futuros. La Figura 22 sugiere que, con el tiempo, los precios de las acciones podrían haberse vuelto más informativos sobre los flujos de caja a corto plazo, pero menos informativos sobre los flujos de caja a largo plazo. En la medida en que la información en

133 Dessaint et al. (2024) examinan 25 artículos que utilizan datos alternativos para pronosticar ganancias corporativas o retornos de acciones. Si bien estos estudios demuestran que los conjuntos de datos alternativos son útiles para predecir resultados a corto plazo, ninguno informa sobre la previsibilidad de los resultados a largo plazo (por ejemplo, ganancias corporativas en un horizonte de dos años o más).

134 Dessaint y otros (2024).

Los precios de las acciones afectan la inversión corporativa, esta evolución podría a su vez cambiar el vencimiento promedio de la inversión corporativa en las empresas, ya que debería estimular la inversión en industrias donde los proyectos de inversión maduran rápidamente (por ejemplo, bienes de consumo) y reducir la inversión en industrias donde maduran lentamente (por ejemplo, minería).¹³⁵

96

Curiosamente, los hallazgos empíricos sobre los efectos de las nuevas tecnologías de la información en la información de los precios en los mercados financieros revelan resultados ambiguos. Esto sugiere que el efecto del progreso en las tecnologías de la información podría ser más complejo que el que sugieren los modelos simples de adquisición de información. Algunos estudios indican que, a largo plazo, las medidas de información de los precios de las acciones han aumentado para los componentes del S&P 500 y las acciones de gran crecimiento, pero han disminuido para otras acciones.¹³⁶ Otros muestran que la disponibilidad de nuevos datos para los inversores tiene un efecto positivo en el precio de las acciones, mientras que otros no encuentran ningún efecto.¹³⁷

Otros estudios han examinado cómo el trading algorítmico afecta la información y la eficiencia de los precios, en particular en el contexto de la divulgación regulatoria. Está bien documentado que, tras la publicación de nuevas presentaciones, como los informes 10-K en el sistema EDGAR, los precios de las acciones suelen mostrar reacciones retardadas, fluctuando al alza o a la baja con el tiempo a medida que los participantes del mercado conocen e interpretan gradualmente la información. La evidencia muestra que el aumento de la actividad de trading algorítmico inmediatamente después de dichas presentaciones, donde se utilizan algoritmos para extraer y procesar rápidamente información relevante, se asocia con ajustes de precios más rápidos.¹³⁸ Esto sugiere que el trading algorítmico puede acelerar la incorporación de nueva información a los precios de las acciones.

Sin embargo, precisamente por esta razón, podría reducir los incentivos para que los intermediarios (por ejemplo, los analistas de seguridad) produzcan información adicional sobre anuncios futuros.

En consonancia con esta lógica, se ha descubierto que los precios de las acciones con mayor actividad comercial algorítmica antes de los anuncios de ganancias son menos informativos sobre estos anuncios.¹³⁹

135 Dessaint et al. (2025) proporcionan evidencia consistente con esta hipótesis.

136 Véase Bai et al. (2015) y Farboodi et al. (2022).

137 Grennan y Michaely (2021) encuentran una asociación positiva entre la cantidad de blogs financieros que cubren una acción y el grado de información de su precio. Zhu (2019) investiga el impacto de dos tipos de datos alternativos (datos de transacciones de consumidores en línea y tasas de utilización de estacionamientos de minoristas a partir de datos de imágenes satelitales) en el grado de información de los precios de las acciones de 266 empresas públicas, utilizando dos medidas de este grado: (i) sensibilidad de los precios de las acciones a las sorpresas en los anuncios de ganancias trimestrales, y (ii) sensibilidad de los retornos de las acciones a las ganancias futuras (de un año). Ambas medidas de este grado de información mejoran para las acciones cubiertas por datos alternativos, pero el efecto es significativo solo para las acciones más líquidas. Katona et al. (2025) no encuentran ningún efecto de la disponibilidad de datos de imágenes satelitales en el grado de información de los precios, mientras que Bonelli y Foucault (2024) encuentran un efecto positivo.

138 Véase Barbopoulos et al. (2023).

139 Intuitivamente, si los precios de las acciones ya reflejan información sobre las ganancias futuras, deberían reaccionar menos a los resultados reales. Divulgación de dichas ganancias. Sin embargo, Weller (2018) encuentra lo contrario: cuando aumenta el trading algorítmico de una acción, las reacciones del precio a los anuncios de ganancias se vuelven más fuertes.

En resumen, si bien la revolución del big data reduce el costo de producir información financiera, no necesariamente resultará en la producción de información con el mayor valor para los consumidores de servicios financieros (p. ej., las empresas). Por ejemplo, si bien las ganancias de eficiencia en la asignación de capital debido a precios de valores más informativos son mayores si estos precios transmiten información difícil de obtener para los tomadores de decisiones (p. ej., los gerentes de las empresas),¹⁴⁰ no existe ningún mecanismo que garantice que los intermediarios financieros utilicen herramientas de IA para producir este tipo de información.

97

3.3.2 Asimetrías informativas y sobreinversión

Una segunda cuestión se refiere a si las herramientas de IA reducen o amplifican las asimetrías de información en los mercados financieros. Si reducen las asimetrías, los costos de selección adversa deberían disminuir, lo que abarataría los costos de transacción para los inversores finales y, a su vez, el costo del capital para las empresas. Si, por el contrario, amplifican las asimetrías, se esperarían los efectos contrarios. Como se explica más adelante, no es evidente cuál de los dos escenarios prevalecerá.

En primer lugar, la evidencia empírica sobre el impacto de la negociación algorítmica en la selección adversa es heterogénea. Algunos hallazgos sugieren que la negociación algorítmica puede mejorar la liquidez del mercado al reducir los costos de selección adversa que enfrentan los proveedores de liquidez.¹⁴¹ Sin embargo, otros estudios presentan una perspectiva más matizada, mostrando que la negociación rápida en torno a eventos noticiosos, a menudo impulsada por algoritmos, puede aumentar la exposición de los proveedores de liquidez a los riesgos de selección adversa (véase la Sección 3.2.1).¹⁴²

En segundo lugar, si bien el auge de los datos alternativos y la digitalización ha reducido el costo de acceder, recopilar y almacenar datos, esto no se traduce automáticamente en un acceso equitativo a información procesable. Por ejemplo, la capacidad de observar un recuento diario de automóviles en los estacionamientos de los comercios minoristas mediante imágenes satelitales, las ventas de las empresas a partir de los datos de tarjetas de crédito o el acceso en línea al informe de divulgación de una empresa reducen el costo de acceder a esta información.¹⁴³ Sin embargo, extraer información significativa y señales comercializables de los datos a menudo exige experiencia en ciencia de datos e inversión sustancial en tecnologías de la información, como la potencia informática.¹⁴⁴ Como resultado, la disponibilidad de nuevos datos podría aumentar las asimetrías informativas entre los inversores que realizan dichas inversiones y los que no.

¹⁴⁰ Como lo demuestran empíricamente Edmans et al. (2017), las decisiones reales dependen no solo de la cantidad total de información en los precios, sino también de la naturaleza de esta información porque un gerente aprende de los precios cuando estos contienen información que desconoce.

¹⁴¹ Véase Hendershott et al. (2011).

¹⁴² Véase, por ejemplo, Budish et al. (2015), Foucault et al. (2017), Brogaard et al. (2017), o Shkillo y Sokolov (2020).

¹⁴³ Por ejemplo, antes de la creación del sistema EDGAR de la SEC en 1993, los inversores debían acudir a una de las tres salas de consulta pública de la SEC en Estados Unidos para consultar las versiones impresas de los informes corporativos de las empresas. Esto era claramente más costoso que descargar las versiones digitales de estos informes del sitio web de la SEC, lo cual ha sido posible desde 1993.

¹⁴⁴ Por ejemplo, Brogaard y Zareei (2023) utilizan algoritmos ML para encontrar reglas comerciales rentables basadas en retornos pasados. Señalan que "el tiempo promedio necesario para encontrar las reglas comerciales óptimas para una cartera diversificada de 10 NYSE/ Los deciles de volatilidad de AMEX para la muestra de 40 años utilizando una computadora con una CPU Intel Core (TM) i7-2600 y 16 GMRAM son 459,29 días". Es decir, con computadoras estándar, usar algoritmos de ML para encontrar reglas comerciales consumiría un tiempo prohibitivo.

En consonancia con esta posibilidad, los efectos del uso de nuevas fuentes de datos y la adopción de tecnologías de la información parecen ser ambiguos. Por ejemplo, se ha demostrado que el grado de información sobre los desequilibrios en las órdenes de los inversores minoristas tras el anuncio de resultados aumenta tras la introducción de sistemas que facilitan el acceso en línea a la información corporativa, lo que sugiere que dichas plataformas pueden contribuir a la democratización de la información y a la igualdad de condiciones.¹⁴⁵ Sin embargo, otras evidencias muestran que las empresas que adoptan formatos de informes digitales estandarizados para la presentación de informes regulatorios pueden experimentar una mayor iliquidez y mayores costes de negociación en comparación con las que no lo hacen, lo que indica que dichos cambios tecnológicos también pueden generar nuevas fricciones.¹⁴⁶

En tercer lugar, como se explica en la Sección 3.1.3, los modelos de IA más complejos tienden a generar predicciones más precisas. Esto permite a los inversores que utilizan estos modelos obtener mayores rendimientos esperados a expensas de los participantes del mercado menos informados. Como resultado, la competencia por desarrollar modelos predictivos cada vez más sofisticados para el trading puede aumentar los costes de selección adversa, especialmente para quienes no pueden seguir el ritmo. La evidencia anecdótica sugiere que esta carrera ya está en marcha, con una creciente demanda tanto de mano de obra cualificada (por ejemplo, científicos de datos) como de potencia de procesamiento.¹⁴⁷ Por ejemplo, un artículo del Financial Times señaló que XTX, una firma de trading por cuenta propia con sede en el Reino Unido, «utiliza 25.000 unidades de procesamiento gráfico para impulsar su investigación, lo que subraya la importancia de la potencia de procesamiento para ejecutar sus al». En comparación, la supercomputadora Leonardo de la UE tiene casi 14.000 GPU [...]».

Dado que el desarrollo y el uso de modelos complejos de IA para el comercio requieren inversiones sustanciales en infraestructura, datos y mano de obra, esta carrera podría generar una inversión excesiva desde una perspectiva social. De hecho, como se explica en la Sección 3.1.3, las empresas de comercio por cuenta propia que realizan estas inversiones no internalizan los costos de selección adversa que generan. Sin embargo, estos costos incrementan los gastos de negociación para los usuarios finales de los mercados financieros, como los hogares y las empresas. Además, el miedo a quedarse atrás en la carrera impulsa a los inversores sofisticados a redoblar sus esfuerzos, como en una carrera armamentística.

Un factor atenuante es que operar con señales más precisas puede mejorar la información de los precios (véase la Sección 3.3.1), lo que puede generar ganancias de eficiencia en la asignación de capital.

Por lo tanto, es necesario equilibrar los costos sociales del comercio informado con las ganancias de eficiencia que surgen de decisiones mejor informadas, como la mejora de la transparencia corporativa.

¹⁴⁵ Véase Gao y Huang (2020).

¹⁴⁶ Véase Blankespoor et al. (2014), quienes estudian los efectos del mandato del Lenguaje Extensible de Informes Empresariales (XBRL) sobre la liquidez. El mandato XLBR exige a las empresas que etiqueten sus estados financieros según una taxonomía desarrollada por la SEC. El etiquetado permite que las aplicaciones de software accedan fácilmente a la información de los estados financieros sin intervención humana. Esto podría haber facilitado la negociación algorítmica de la información de los estados financieros de las empresas y aumentado las asimetrías informativas. De igual manera, Katona et al. (2025) observan que los desequilibrios en las órdenes de los inversores individuales se vuelven menos informativos y los costes de negociación aumentan después de que una acción se cubre con nuevos datos alternativos, en este caso, imágenes satelitales. Interpretan este hallazgo como evidencia de que solo los inversores sofisticados pueden permitirse el coste de obtener y procesar datos alternativos.

¹⁴⁷ "Las fábricas cuantitativas que producen los gestores de fondos del mañana", Financial Times, 2 de junio de 2018; "El operador de alta velocidad XTX", "Los mercados construirán un gran centro de datos en Finlandia", Financial Times, 12 de abril de 2024.

Inversión. Además, existen otras aplicaciones de la IA en la inversión donde la alineación entre los beneficios privados y sociales es más clara. Por ejemplo, como se analiza en la Sección 3.2.2, los modelos de IA pueden ayudar a los inversores de capital riesgo a predecir la probabilidad de éxito de nuevas empresas, lo que permite una asignación de capital más eficiente.

99

El análisis anterior se centra en las asimetrías de información entre inversores debido a la inversión desigual en tecnologías de procesamiento de datos. La acumulación de datos por parte de las empresas (sobre sus clientes, proveedores, etc.) también puede agravar las asimetrías de información entre empresas (de adentro) e inversores (de afuera), un tema que se analiza en detalle en el capítulo 4 de este informe.

3.3.3 Algoritmos de fijación de precios, poder de mercado y costos comerciales

En los mercados de consumo (por ejemplo, transporte, entretenimiento, venta minorista), los mercados de plataformas (por ejemplo, viajes compartidos) o los mercados inmobiliarios ('iBuyers'), las empresas (por ejemplo, compañías aéreas, cadenas hoteleras, agentes inmobiliarios) dependen cada vez más de algoritmos para establecer dinámicamente los precios de sus servicios.¹⁴⁸ Estos algoritmos de fijación de precios utilizan reglas computarizadas para ajustar los precios de los productos en función de diversas entradas (datos), como los precios de los competidores, los volúmenes de transacciones o las características de los consumidores.¹⁴⁹ Esta evolución permite a las empresas ajustar los precios de numerosos productos a un costo mucho menor y con una frecuencia mucho mayor que cuando dependen de la intervención humana.¹⁵⁰

Un número creciente de estudios examina si dichos algoritmos mejoran o debilitan la competencia en los mercados de productos. En particular, juristas y reguladores han expresado recientemente su preocupación por la posibilidad de que los algoritmos de autoaprendizaje aprendan de forma independiente a mantener precios no competitivos y resultados colusorios, aunque dicho comportamiento no sea intencionado explícitamente por sus usuarios.¹⁵¹



¹⁴⁸ iBuyers (p. ej., OpenDoor, OfferPad, Zillow) son creadores de mercado en el mercado inmobiliario. Se basan en modelos de valoración automatizados para realizar ofertas rápidas de efectivo a los vendedores de viviendas; véase Buchak et al. (2022).

¹⁴⁹ Véase MacKay y Weinstein (2022) y OCDE (2017).

¹⁵⁰ Véase Brown y MacKay (2023) para obtener evidencia.

¹⁵¹ Véase, por ejemplo, OCDE (2017), Ezrachi y Stuche (2017) o MacKay y Weinstein (2022). Véase también "Policing the La Comisaría de Competencia de la UE, Vestager, la FTC de los EE. UU., la Autoridad del Mercado de Competencia (CMA) del Reino Unido y las autoridades de competencia de Francia, Alemania y Canadá han expresado su preocupación por el riesgo de colusión entre los algoritmos de fijación de precios.

Sin embargo, la evidencia de campo sobre este tema aún es muy escasa.¹⁵² Por lo tanto, para evaluar si estas preocupaciones están justificadas, se han considerado estudios experimentales en los que la fijación de precios se delega en algoritmos de autoaprendizaje. El comportamiento de estos algoritmos se analiza posteriormente mediante simulaciones en diversos entornos. ¹⁵³ Estos estudios concluyen que los algoritmos pueden aprender a mantener resultados no competitivos sin estar programados explícitamente para ello y sin necesidad de comunicación.

En un estudio histórico, Calvano et al. (2020a) analizan agentes artificiales ('empresas') que compiten experimentalmente y venden productos diferenciados. Los agentes utilizan algoritmos de aprendizaje Q (un algoritmo fundamental de aprendizaje por refuerzo) para fijar precios.¹⁵⁴ Dado que los agentes interactúan repetidamente y pueden condicionar sus estrategias de fijación de precios a precios pasados, en teoría existe margen para mantener equilibrios colusorios mediante la amenaza implícita de guerras de precios en caso de desviaciones. Los autores observan que, en sus experimentos, los algoritmos adoptan estrategias que generan beneficios muy superiores a los niveles competitivos de media. Además, cuando un algoritmo se desvía de los precios supracompetitivos que finalmente establecen (los 'precios a largo plazo'), desencadena respuestas de otros algoritmos que se asemejan a guerras de precios. En concreto, los demás algoritmos también bajan sus precios, lo que reduce los beneficios de todos los participantes.

Evidencia similar surge de entornos donde agentes artificiales compiten fijando precios para productos idénticos en turnos alternos. En tales entornos, se ha observado que los algoritmos empleados por estos agentes adoptan estrategias de precios que favorecen precios supracompetitivos. Curiosamente, algunas de estas estrategias se asemejan a los ciclos de Edgeworth, donde los algoritmos aprenden a reajustar los precios a niveles más altos tras períodos de intensa competencia.¹⁵⁵

El análisis de la fijación algorítmica de precios en los mercados de productos sigue siendo limitado, y los hallazgos analizados hasta el momento requieren confirmación mediante investigaciones adicionales.¹⁵⁶ No obstante, dadas las preocupaciones planteadas por las autoridades de competencia sobre la fijación algorítmica de precios, resulta sorprendente que no se hayan expresado preocupaciones similares en los mercados financieros, donde los creadores de mercado han dependido durante mucho tiempo de algoritmos para fijar sus precios (véase la Sección 3.2.1 y la Figura 19). Una posible razón es la presunción de que la competencia entre los creadores de mercado de alta frecuencia (aquellos que utilizan algoritmos de fijación de precios) es tan intensa que el poder de mercado no constituye una preocupación.¹⁵⁷

Assad et al. (2024) estudian la adopción de algoritmos de precios en el mercado minorista alemán de gasolina. Observan que la adopción de dichos algoritmos por parte de las gasolineras generó un aumento del margen del 9 % en mercados con múltiples competidores (y del 28 % en un entorno de duopolio).

153 El enfoque consiste en establecer un entorno simple de teoría de juegos con propiedades conocidas en economía y estudiar el comportamiento de algoritmos de autoaprendizaje en dicho entorno. Este enfoque es similar al de la economía experimental, salvo que las decisiones las toman algoritmos en lugar de humanos. El uso de simulaciones se debe a que, en general, las decisiones a largo plazo de los algoritmos de refuerzo no pueden derivarse fácilmente analíticamente, a pesar de la simplicidad del algoritmo.

154 El aprendizaje Q fue introducido inicialmente en informática por Watkins y Dayan (1992). Véase Sutton y Barto (2019) para una introducción del libro de texto.

155 Véase Klein (2021).


156 Para otros estudios sobre este tema, véase Asker et al. (2024) o Johnson et al. (2023).

157 Los estudios académicos sobre este tema son escasos. De hecho, la mayoría de las investigaciones se centran en la competencia entre empresas de negociación de alta frecuencia para aprovechar oportunidades de arbitraje de corta duración o cotizaciones obsoletas, en lugar de en la competencia por la provisión de liquidez (p. ej., Aquilina et al., 2024; Breckenfelder, 2024). Una excepción es Brogaard y Garriott (2019). Véase más adelante.

Sin embargo, esta creencia podría no estar justificada por varias razones. En primer lugar, en la práctica, la provisión de liquidez parece estar concentrada en manos de las firmas de creación de mercado más rápidas, observándose una relación positiva entre la concentración de la oferta de liquidez por parte de los operadores de alta frecuencia y los diferenciales entre oferta y demanda.¹⁵⁸ Por ejemplo, en Euronext (la bolsa paneuropea), las seis principales firmas de trading algorítmico representan más del 70% de la actividad de trading (véase la Figura 23). Otros estudios académicos presentan hallazgos similares respecto a la concentración de la actividad de trading en un pequeño número de firmas de trading por cuenta propia muy rápidas. Por ejemplo, la evidencia de una muestra de trading en 25 acciones suecas¹⁵⁹ muestra que la heterogeneidad en las velocidades relativas entre las firmas de trading de alta frecuencia actúa como una importante barrera de entrada. Las firmas más rápidas (alrededor de cinco) captan una parte desproporcionadamente grande de los ingresos totales por trading, mientras que los nuevos participantes tienden a tener un rendimiento inferior y a salir del mercado rápidamente. Además, este dominio se mantiene estable durante todo el período de la muestra, incluso a medida que aumenta la velocidad general de los operadores de alta frecuencia.

101

FIGURA 23 ACTIVIDAD NEGOCIADORA DEL MERCADO DE RENTA VARIABLE DE EURONEXT POR PARTICIPANTES MÁS ACTIVOS (%)



Fuente FMI (2024).

En segundo lugar, aunque las teorías suelen asumir que la competencia entre creadores de mercado impulsa los precios a niveles competitivos, la evidencia empírica sugiere que la realidad es más matizada. Por ejemplo, Hendershott et al. (2011) concluyen que la negociación algorítmica reduce los diferenciales de oferta y demanda. Sin embargo, esta reducción se debe a una disminución de los costes de selección adversa que enfrentan los proveedores de liquidez, más que a una disminución de sus beneficios.

De hecho, los autores informan que el comercio algorítmico tiene un impacto positivo en las ganancias realizadas por los distribuidores.

158 Véase Brogaard y Garriott (2019), Figura 4.
159 Véase Baron et al. (2019).

diferenciales entre oferta y demanda: una medida de la ganancia por acción de los distribuidores, neta de costos de selección adversa. Al comentar este hallazgo, escriben: "Esto es sorprendente porque inicialmente esperábamos que si AT mejoraba la liquidez, el mecanismo sería la competencia entre proveedores de liquidez".

102

Además, la dinámica de los diferenciales entre oferta y demanda de los creadores de mercado de alta frecuencia tras la entrada de nuevos competidores parece más compleja que la predicha por modelos simples de competencia de precios en los mercados financieros. Dichos modelos suelen implicar que dos competidores son suficientes para impulsar los precios a niveles competitivos. En realidad, como encontraron Brogaard y Garriott (2019), este no parece ser el caso. Estos investigadores han estudiado la entrada de operadores de alta frecuencia en Alpha, la segunda plataforma de negociación más grande para acciones canadienses. Observan una disminución gradual en los diferenciales entre oferta y demanda para una acción a medida que aumenta el número de creadores de mercado de alta frecuencia en esta acción. Por lo tanto, se necesitan más de dos creadores de mercado para alcanzar el resultado competitivo, en contraste con lo que predecirían los modelos simples de competencia de precios.

Por supuesto, incluso si la competencia entre creadores de mercado algorítmicos es imperfecta, podría generar resultados más competitivos que en mercados dominados por creadores de mercado humanos. La cuestión es que (i) la concentración entre los proveedores de liquidez algorítmica y (ii) la transición de algoritmos basados en reglas a algoritmos de autoaprendizaje podrían limitar los beneficios de reemplazar a los creadores de mercado humanos por máquinas.

Se necesita más investigación para evaluar este riesgo. Un enfoque posible, similar al utilizado en los mercados de productos, consiste en estudiar el comportamiento de los algoritmos en mercados experimentales, considerando las características específicas de los mercados financieros. En primer lugar, los proveedores de liquidez que compiten en los mercados financieros venden un producto homogéneo (todas las acciones de una misma empresa son sustitutivas perfectas). En segundo lugar, los creadores de mercado en los mercados financieros se enfrentan al riesgo de operar con inversores mejor informados, lo que genera costos de selección adversa. Por último, el valor de sus inventarios puede fluctuar significativamente a lo largo del tiempo, lo que genera costos de mantenimiento de inventario (por ejemplo, los creadores de mercado deben recibir una compensación adecuada por la asunción de riesgos). Estos costos difieren fundamentalmente de los costos de producción que incurren las empresas en los mercados de productos.

Un estudio reciente adopta este enfoque y examina un entorno en el que los creadores de mercado algorítmicos, utilizando algoritmos de aprendizaje Q, compiten en precios para ejecutar órdenes de compra de un activo riesgoso.¹⁶⁰ Los creadores de mercado se enfrentan a una selección adversa porque sus clientes tienen más probabilidades de comprar el activo cuando su rentabilidad (desconocida para los creadores de mercado) es alta que cuando es baja.

¹⁶⁰ Colliard y otros (2023).

El estudio revela que los creadores de mercado algorítmicos aprenden a considerar los costos de selección adversa: sus diferenciales cotizados aumentan a medida que estos costos aumentan y, tras un período de entrenamiento, no incurren en pérdidas en promedio. Sin embargo, tienden a establecer precios no competitivos. Sorprendentemente, sus precios se acercan a los niveles competitivos en entornos con mayores costos de selección adversa, lo cual contradice el análisis económico estándar. Este sorprendente resultado resalta la necesidad de desarrollar nuevos enfoques para predecir y explicar los resultados (liquidez, formación de precios, etc.) en los mercados financieros cuando los precios se fijan mediante algoritmos.

103

Otro estudio realiza experimentos en los que algoritmos aprenden a explotar información privada sobre la rentabilidad de un activo de riesgo.¹⁶¹ En estos experimentos, los algoritmos deciden cuántas acciones del activo comprar o vender basándose en una señal privada sobre su rentabilidad. El contexto permite que los inversores informados (los algoritmos) aumenten sus beneficios promedio al acordar reducir el tamaño de sus órdenes en comparación con lo que sería individualmente óptimo si no pudieran llegar a un acuerdo. Esta estrategia constituye una forma de comportamiento colusorio, ya que permite a los inversores informados obtener mayores beneficios de otros participantes del mercado.

Este estudio revela que, bajo ciertas parametrizaciones del entorno, los algoritmos aprenden la estrategia colusoria. Este hallazgo proporciona otro ejemplo, en el contexto de los mercados financieros, de la capacidad de los algoritmos de autoaprendizaje para desarrollar estrategias comerciales de búsqueda de rentas.

En resumen, el auge de los algoritmos de autoaprendizaje en los mercados financieros plantea inquietudes sobre la competencia, similares a las observadas en los mercados de consumo. Si el comercio impulsado por IA permite a los intermediarios (por ejemplo, los creadores de mercado) mantener ganancias supracompetitivas, la reducción resultante en los costos de intermediación derivada de la adopción de IA será limitada.

3.3.4 Explicabilidad, rendición de cuentas y personas involucradas

Los algoritmos de aprendizaje automático a menudo se describen como "cajas negras" porque es difícil entender cómo generan su resultado (una predicción o una decisión) a partir de la entrada dada (datos).¹⁶²

Una razón es que los modelos predictivos pueden involucrar una gran cantidad de características y parámetros, lo que dificulta comprender cuáles son importantes y por qué son relevantes para las predicciones. De igual manera, el proceso de toma de decisiones de los algoritmos de autoaprendizaje suele ser difícil de explicar, lo cual puede resultar desconcertante para los humanos. Por ejemplo, durante las partidas entre AlphaGo (un programa informático desarrollado por DeepMind para jugar al Go) y Lee Sedol, campeón mundial de Go, muchos de los movimientos de AlphaGo fueron considerados muy inusuales e incluso erróneos por los comentaristas. Sin embargo, en retrospectiva, estos movimientos resultaron exitosos, ya que AlphaGo ganó cuatro de cinco partidas.

¹⁶¹ Dou y otros (2023).

¹⁶² Véase, por ejemplo, "La IA no debería ser una caja negra", Financial Times, 30 de mayo de 2024.

La falta de explicabilidad no se debe necesariamente a la complejidad de los algoritmos en sí, sino a la complejidad de interpretar su comportamiento. Por ejemplo, como se mencionó anteriormente, varios estudios académicos concluyen que los algoritmos de autoaprendizaje pueden mantener resultados no competitivos sin estar diseñados explícitamente para ello y sin ninguna comunicación entre algoritmos. Los algoritmos examinados en estos estudios son simples, en el sentido de que sus operaciones paso a paso son fáciles de describir. Sin embargo, el comportamiento que finalmente adoptan es difícil de explicar y, por lo tanto, difícil de predecir.

El problema de la explicabilidad plantea varios desafíos para los responsables políticos. En primer lugar, dificulta la detección y regulación del abuso de mercado. Como se explicó en la sección anterior, los algoritmos de autoaprendizaje podrían aprender a coordinar estrategias de búsqueda de rentas —a expensas de otros participantes del mercado— sin comunicación alguna y sin estar programados explícitamente para ello. Esto dificulta la justificación de la colusión y crea nuevos tipos de problemas de agencia (véase el capítulo 4 para más información).¹⁶³

De manera similar, el autoaprendizaje podría aprender involuntariamente a manipular los precios.¹⁶⁴ Por ejemplo, en ciertos modelos donde los creadores de mercado utilizan algoritmos de autoaprendizaje para gestionar el riesgo de inventario, estos algoritmos a veces pueden comportarse de maneras que se asemejan a la táctica de manipulación conocida como «spoofing», a pesar de que su diseño está destinado exclusivamente a la gestión de inventario.¹⁶⁵ En casos de manipulación de precios, los fiscales y demandantes deben proporcionar pruebas convincentes de la intención de manipular. Hacerlo se vuelve más difícil cuando el comportamiento de los algoritmos comerciales involucrados en tales casos no puede explicarse fácilmente o cuando, a pesar de haber sido diseñados para otras actividades, siguen comportamientos manipuladores.

Otra cuestión importante es la rendición de cuentas. En este caso, el reto reside en establecer la responsabilidad legal en casos de abuso de mercado por parte de un algoritmo de autoaprendizaje, ya que el algoritmo en sí no es una entidad jurídica independiente. Un enfoque consiste en atribuir la responsabilidad a la organización o a las personas que utilizan el algoritmo. Sin embargo, esto se vuelve controvertido cuando el algoritmo aprende su comportamiento de forma independiente. En tales casos, los usuarios pueden argumentar que no pudieron prever la cadena de acontecimientos que condujo al abuso de mercado, especialmente si el comportamiento del algoritmo es inherentemente difícil de predecir y explicar.

La falta de rendición de cuentas puede, a su vez, reducir los incentivos de los usuarios para actuar con cautela al diseñar e implementar algoritmos autónomos, especialmente en el contexto de una carrera por la innovación. Esto podría exacerbar los riesgos operativos. De hecho, la última década ha presenciado fallos espectaculares causados por algoritmos comerciales mal diseñados.

¹⁶³ Véase Calvano et al. (2020b) y Mackay y Weinstein (2022) para un análisis en el contexto de los mercados de consumo.

¹⁶⁴ La manipulación de precios en los mercados financieros se refiere a un intento deliberado de alterar los precios de uno o varios activos o de utilizar medios engañosos para inducir a otros inversores a operar. Véase Hacker (2023) para la cuestión más general de la manipulación humana mediante algoritmos.

¹⁶⁵ Véase Cartea et al. (2023). La suplantación de identidad consiste en colocar, por ejemplo, órdenes de compra limitadas para un valor, para dar la impresión de una fuerte demanda mientras se espera que el precio suba, vender y finalmente cancelar las órdenes de compra limitadas. Esta práctica es manipuladora porque da una impresión errónea de la demanda real del valor. El número de casos legales relacionados con la suplantación de identidad ha aumentado en los últimos años, incluyendo una multa de 920 millones de dólares impuesta a JP Morgan en 2020.

Por ejemplo, el evento desencadenante del Flash Crash del 6 de mayo de 2010 fue un algoritmo defectuoso que ejecutaba grandes órdenes de venta en los futuros E.mini del índice S&P 500.¹⁶⁶ La velocidad de ejecución del algoritmo fue demasiado rápida dada la profundidad disponible en los futuros E.mini, lo que desencadenó una rápida caída de los precios que se propagó al mercado bursátil mediante arbitraje cruzado. Otro ejemplo es Knight Capital, una de las mayores empresas estadounidenses de creación de mercado hasta 2012, que perdió alrededor de 460 millones de dólares en un solo día debido a un mal funcionamiento de sus algoritmos el 1 de agosto de 2012.

105

Abordar los desafíos que plantean la explicabilidad y la rendición de cuentas es, por lo tanto, una cuestión apremiante.¹⁶⁷ Esto requiere (i) replantear las normas de cumplimiento que rigen el uso de algoritmos de negociación,¹⁶⁸ y (ii) más investigación sobre el uso de algoritmos autónomos en los mercados financieros para orientar el diseño de estas normas. Las posibles intervenciones políticas incluyen exigir a las empresas de negociación por cuenta propia y a los gestores de fondos que revelen más información sobre el funcionamiento de sus algoritmos de IA y los datos que utilizan, exigir el uso de técnicas de IA explicables y garantizar la presencia de un "humano en el circuito" para supervisar los algoritmos y desactivarlos si es necesario, de forma similar a los pilotos de una aeronave en piloto automático.

Mantener a los humanos informados también podría ayudar a aprovechar las complementariedades entre humanos y máquinas. Estas complementariedades surgen de tres posibles fuentes. En primer lugar, los humanos pueden tener acceso a información que las máquinas no tienen o poseer formas únicas de procesar información que estas no pueden replicar fácilmente. En tales casos, incluso si las predicciones algorítmicas son más precisas en general, la combinación de pronósticos humanos y de máquinas puede generar una precisión predictiva aún mayor. Numerosos estudios aportan evidencia que respalda esta posibilidad (véase la Sección 3.2.1).

En segundo lugar, a diferencia de los algoritmos de aprendizaje automático (al menos hasta ahora), los procesos de predicción y toma de decisiones de los humanos se basan en un "modelo del mundo". Esto permite a los humanos realizar predicciones y tomar decisiones en circunstancias en las que las máquinas probablemente tengan un rendimiento deficiente. Los algoritmos de aprendizaje automático se entrenan con datos existentes, lo que significa que la relación entre los estados (puntos de datos) y las predicciones o decisiones se aprende solo para los estados observados. Para estados poco frecuentes (o "eventos de cola"), las máquinas deben extrapolar, lo que aumenta el riesgo de predicciones y decisiones deficientes. Por ejemplo, ante condiciones de mercado poco frecuentes, el mercado algorítmico...

Regulación

¹⁶⁶ Véase Foucault et al. (2024), Capítulo 9, para detalles y otros ejemplos.

¹⁶⁷ Otra cuestión es la "equidad": la posibilidad de que los algoritmos de aprendizaje automático amplifiquen los sesgos de discriminación al encontrar formas de condicionar los resultados a variables que no se pueden utilizar para tomar una decisión (p. ej., género o raza) o que no son fáciles de observar. Esta cuestión es muy relevante en el contexto de las decisiones de préstamos o seguros, y menos en el contexto del comercio (p. ej., Fuster et al., 2022; Hurlin et al., 2023).

¹⁶⁸ Los reguladores han tomado medidas en esta dirección (véase ESMA, 2020).

Los creadores de mercados podrían optar por dejar de proporcionar liquidez por no haber recibido la capacitación necesaria para operar en tales casos. Esto puede provocar una evaporación repentina de la liquidez y hacer que las condiciones del mercado sean aún más excepcionales.^{169,170} En cambio, los humanos, al basarse en sus modelos del mundo, pueden estar mejor preparados para interpretar las condiciones y actuar en tales casos.¹⁷¹

En tercer lugar, si bien las máquinas pueden predecir estados y aprender a tomar decisiones condicionadas a su ocurrencia, solo los humanos pueden determinar el beneficio o la utilidad asociada a una decisión dada en un estado específico. Agrawal et al. (2017, 2018) denominan a esta capacidad «juicio».

El juicio es importante, por ejemplo, para los algoritmos de aprendizaje por refuerzo, cuyo comportamiento depende, en última instancia, de la especificación de la «recompensa» por una acción en un estado dado. Esta especificación la elige el programador y depende de sus objetivos.

Los programadores deberían poder explicar esta especificación y ser responsables de ella.

3.4 CONCLUSIÓN: IMPLICACIONES POLÍTICAS

La adopción de herramientas de IA en el sector de valores reduce el coste de la producción de información financiera y, por lo tanto, puede disminuir los costes de intermediación. Esta evolución puede reducir el riesgo.

Compartir costos (p. ej., mediante menores costos de diversificación) y costos de financiamiento (p. ej., mediante menores costos de comercialización) para los usuarios finales. Además, métodos predictivos más potentes deberían permitir que los precios de los valores reflejen mejor los flujos de caja futuros, lo que a su vez debería resultar en una asignación más eficiente del capital. Por todas estas razones, la revolución del big data puede generar importantes mejoras en el bienestar de los consumidores de servicios financieros (hogares, empresas y gobierno). Sin embargo, como se explica en la Sección 3.3, existen riesgos de que estas mejoras no se alcancen plenamente por dos razones distintas: (i) fallas del mercado y (ii) fallas operativas.

Las fallas del mercado se derivan de fricciones familiares para los responsables de las políticas en los mercados financieros, a saber, la selección adversa, el poder de mercado y las externalidades. Por ejemplo, el riesgo de sobreinversión, analizado en la Sección 3.3.2, se deriva del hecho de que, cuando los inversores operan con información privada, generan costos de selección adversa que, en última instancia, pagan todos los inversores. Por lo tanto, operar con información privada es una externalidad negativa:

169 Por ejemplo, en un discurso pronunciado el 30 de mayo de 2024, Gita Gopinath, del FMI, señaló que «en una futura recesión caracterizada por patrones desconocidos, incluyendo patrones desconocidos de pérdida de empleos, los sistemas de IA podrían tener dificultades para responder. Esto se debe a que se ha demostrado que la IA tiene un rendimiento deficiente ante eventos novedosos, es decir, eventos que difieren notablemente de los datos con los que ha sido entrenada. Como resultado, podrían volverse rápida y simultáneamente excesivamente conservadores y reequilibrar las carteras hacia activos seguros. La decisión de los modelos de abandonar otros activos se verá recompensada a medida que sus precios caen, y podría producirse una espiral de ventas forzadas y un colapso de los precios de los activos en diferentes mercados financieros» (Gopinath, 2024).

170 Véase Cespa y Vives (2025) y Cespa y Foucault (2014) para modelos en los que la liquidez se evapora repentinamente, lo que lleva a las caídas del mercado.

171 Por ejemplo, Bonelli (2024) concluye que los fondos de capital riesgo basados en datos —aquellos que utilizan técnicas de inteligencia artificial para identificar y seleccionar nuevos proyectos— tienden a invertir en startups que persiguen modelos de negocio similares a los de las startups existentes. Este enfoque reduce las tasas de fracaso. Sin embargo, reduce la probabilidad de seleccionar startups de gran éxito (aquellas que cotizan en bolsa o son adquiridas por otras empresas) y proyectos verdaderamente innovadores. Por definición, los resultados de estos proyectos no se han observado en el pasado, lo que dificulta su predicción mediante herramientas de IA. Esto ilustra una limitación del aprendizaje automático.
Algoritmos para la toma de decisiones en finanzas.

Reduce la liquidez de los mercados de valores. Al decidir cuánto invertir en tecnologías de la información, los inversores comparan la rentabilidad esperada que pueden obtener con información privada con el coste de estas tecnologías, pero no internalizan los costes de selección adversa. Como resultado, se produce una inversión excesiva.

El riesgo de que los inversores no aprovechen las reducciones en el coste de producción de información para generar información de alto valor social también constituye un problema de externalidad. Los inversores que producen información privada hacen que los precios sean más informativos sobre los fundamentos al operar con base en dicha información. Esto constituye una externalidad positiva (un bien público) porque los responsables de la toma de decisiones pueden utilizar la información contenida en los precios de los valores como fuente de información para decisiones reales (por ejemplo, inversiones corporativas). Quienes producen esta información se ven recompensados con las ganancias de sus operaciones. El problema radica en que no existe un mecanismo que alinee la magnitud de estas ganancias con el valor social de la información producida para generarlas. Por lo tanto, no se debe esperar necesariamente que los inversores aprovechen al máximo las nuevas tecnologías de producción de información financiera para la sociedad. Por ejemplo, un inversor que utiliza algoritmos para reaccionar rápidamente a las noticias puede obtener grandes ganancias comerciales seleccionando cotizaciones obsoletas. Este inversor procesa la información para tomar sus decisiones comerciales. Sin embargo, dicho procesamiento de información tiene escaso valor social, ya que la información de las noticias se reflejará en los precios de todos modos, independientemente de si el inversor opera con base en esta información.

Los dos problemas anteriores son, en cierto modo, imágenes especulares. Una forma de resolver el primero es reducir el margen para la negociación de información privada en los mercados de valores. Sin embargo, al hacerlo, se eliminan los incentivos para producir información privada, a costa de que los precios de los valores sean menos informativos. Resolver este dilema de forma óptima no es fácil, sobre todo porque los costes y beneficios de la producción de información privada para la sociedad son difíciles de medir. Como mínimo, los responsables políticos deberían esforzarse por limitar la negociación de información que claramente carece de valor social, como la negociación de información ya disponible (por ejemplo, explotar la información de los anuncios macroeconómicos una fracción de segundo antes que otros participantes del mercado debido a una mayor capacidad para procesar el anuncio). Las innovaciones en el diseño del mercado pueden ser útiles para lograrlo.

Además, el uso de agentes autodidactas en los mercados de valores crea una especie de separación entre propiedad y control: los humanos poseen los algoritmos, pero delegan en ellos la toma de decisiones. Esto plantea inquietudes sobre la capacidad de los humanos para comprender cómo los algoritmos generan decisiones y sobre la responsabilidad cuando su comportamiento es ilegal (p. ej., la manipulación de precios) o desestabilizador (p. ej., el Flash Crash de 2010, desencadenado por un algoritmo mal diseñado). Esto genera riesgos operativos novedosos para los responsables políticos de los mercados de valores.

172 Por ejemplo, para proteger a los inversores desinformados del riesgo de ser estafados, algunos han propuesto crear mercados «lentos» (IEX es uno de ellos; véase <https://www.iexexchange.io/>) que operen en paralelo con los mercados «rápidos». Otra propuesta es el uso de subastas periódicas y frecuentes por lotes (Budish et al., 2015). Balfauf y Mollner (2020) estudian diseños de mercado que equilibran óptimamente la producción de información con el coste de la illiquidez.

A diferencia de otras industrias (por ejemplo, el transporte o la energía), los reguladores de la industria de valores históricamente han estado menos preocupados por la seguridad de las tecnologías comerciales. Esto puede deberse a que, hasta hace poco, estas tecnologías eran relativamente sencillas y era improbable que las fallas operativas tuvieran efectos sistémicos. Sin embargo, la adopción de algoritmos de autoaprendizaje cambia radicalmente las reglas del juego. En particular, dado que el comportamiento de estos algoritmos es difícil de explicar, también resulta complicado predecir cómo actuarán en entornos donde sus decisiones son interdependientes o cómo responderán a shocks inesperados. Esta falta de previsibilidad genera incertidumbre, lo que podría socavar la confianza de los inversores en los mercados financieros y ser una fuente potencial de riesgo sistémico.

Abordar estos problemas requiere el desarrollo de estándares de seguridad para los algoritmos de negociación en los mercados financieros. Algunos requisitos regulatorios ya existen. Por ejemplo, en Estados Unidos, el Reglamento de la SEC "Cumplimiento e Integridad de los Sistemas" (SCI) exige que las instituciones financieras clave, como las bolsas y las cámaras de compensación, mantengan sistemas de negociación resilientes y seguros. En la Unión Europea, la Directiva de Mercados de Instrumentos Financieros II (MiFID II) impone controles de riesgo en la negociación algorítmica, requiriendo que las empresas implementen interruptores de circuito, interruptores de seguridad (para desactivar algoritmos cuando se comportan erráticamente) y procedimientos de prueba para sus algoritmos. El marco de Cumplimiento de la Negociación Algorítmica de la FCA del Reino Unido exige que las empresas se aseguren de que la negociación algorítmica no genere mercados desordenados e incluya controles para la gestión de riesgos.

El desarrollo de algoritmos de autoaprendizaje exige la expansión de estas iniciativas. La Ley de IA de la UE, finalizada en 2024, busca proporcionar un marco regulatorio para garantizar una IA segura. Clasifica los sistemas de IA en diversas categorías de riesgo (prohibido, de alto riesgo, de riesgo limitado y de riesgo mínimo) e impone requisitos de cumplimiento en consecuencia.¹⁷³ Los sistemas de IA de alto riesgo deben ser explicables, monitoreados por humanos, robustos y precisos (por ejemplo, probados contra ataques adversarios).

Estados Unidos y el Reino Unido han adoptado un enfoque menos prescriptivo, basándose en la autorregulación y el desarrollo de parámetros de seguridad por parte de organismos especializados. En particular, el Reino Unido ha creado el Instituto de Seguridad de la IA (AISI), cuyo objetivo es realizar investigaciones y construir infraestructura para evaluar la seguridad de los sistemas de IA y su impacto en la sociedad.¹⁷⁴ Los reguladores de los mercados financieros y las empresas que utilizan algoritmos para la negociación de valores podrían recurrir de forma más sistemática a dichos institutos para probar los algoritmos de negociación antes de su puesta en funcionamiento. Esto ayudaría a identificar posibles fallos en estos algoritmos, especialmente cuando interactúan con otros, mediante procedimientos de prueba sistemáticos y estandarizados.

¹⁷³ Aún no existe un marco regulatorio similar para la IA en Estados Unidos. El presidente Biden emitió una Orden Ejecutiva el "Desarrollo y uso seguro, protegido y confiable de la inteligencia artificial" en octubre de 2023, pero esta orden fue revocada por la administración Trump en enero de 2025.

¹⁷⁴ Véase <https://www.aisi.gov.uk/>.

CAPÍTULO 4

Finanzas corporativas y gobernanza con inteligencia artificial: lo antiguo y lo nuevo

109

4.1 INTRODUCCIÓN

El propósito de este capítulo es explorar el rol evolutivo de la IA en las finanzas corporativas, centrándose en cómo reconfigura los paradigmas tradicionales e introduce nuevas oportunidades y desafíos. Muchos de los problemas abordados en las finanzas corporativas (problemas de agencia, asimetría de la información y contratación incompleta) tienen raíces en teorías económicas clásicas, como los costos de agencia,¹⁷⁵ la información asimétrica¹⁷⁶ y la contratación incompleta.¹⁷⁷ Al explorar la interacción entre "algo viejo" y "algo nuevo", este capítulo busca resaltar tanto la naturaleza perdurable de las teorías clásicas como la evolución de las oportunidades y los desafíos en una era cada vez más moldeada por la IA. Desde esta perspectiva, proponemos un marco que conecta los principios históricos con las complejidades emergentes impulsadas por la innovación tecnológica. Al tender un puente entre el pasado y el presente, el capítulo proporciona una hoja de ruta para abordar los desafíos emergentes en las finanzas y la gobernanza corporativa en la nueva era de las tecnologías impulsadas por la IA.

Tradicionalmente, los problemas de agencia describen conflictos de intereses que surgen cuando los agentes no alinean completamente sus acciones con los objetivos de sus principales. En la era de la IA, esta dinámica ha evolucionado hacia una nueva forma de dilema de agencia. Los sistemas de IA, que desempeñan roles como oráculos, agentes o soberanos, ejecutan tareas basadas en funciones objetivo predefinidas. Estos sistemas no presentan riesgo moral en el sentido tradicional (no hay interés propio ni deseo de beneficios), pero pueden optimizar objetivos de maneras que perjudiquen inadvertidamente a sus principales. Por ejemplo, los algoritmos de aprendizaje de refuerzo en el comercio algorítmico pueden desarrollar estrategias que imitan comportamientos ilícitos, como la suplantación de identidad, sin estar programados explícitamente para ello. Esta falta de interpretabilidad e intención dificulta la asignación de responsabilidades o la regulación efectiva del comportamiento. Por lo tanto, el nuevo problema de agencia se extiende más allá de la alineación de objetivos para garantizar la transparencia, la rendición de cuentas y mecanismos de supervisión robustos para los agentes impulsados por IA.

¹⁷⁵ Jensen y Meckling (1976).

¹⁷⁶ Myers y Majluf (1984).

¹⁷⁷ Hart y Moore (1988).

De igual manera, la asimetría de la información, piedra angular de las finanzas corporativas,¹⁷⁸ está experimentando profundos cambios. Históricamente, quienes tenían información privilegiada tenían ventajas gracias a la propiedad intelectual, pero la proliferación de datos alternativos, como imágenes satelitales, agregadores de transacciones con tarjetas de crédito y rastreo de geolocalización, ha transformado esta dinámica. Estas tecnologías generan información cada vez más externa a las empresas, a menudo ignorando a los propios directivos. La IA amplifica esta tendencia al permitir el procesamiento e interpretación rápidos de dichos datos, creando disparidades incluso entre participantes del mercado aparentemente iguales. Por ejemplo, los fondos de cobertura que utilizan datos satelitales para rastrear el tráfico minorista o las descargas automáticas de documentos regulatorios obtienen ventajas significativas, creando asimetrías de información pública. Como resultado, si bien los datos alternativos democratizan el acceso a la información, también exacerban las desigualdades en las capacidades de procesamiento, desafiando los marcos regulatorios tradicionales como Reg FD.

El tercer pilar, la contratación incompleta, también enfrenta una transformación a medida que los contratos inteligentes basados en blockchain ganan terreno.¹⁷⁹ Estos contratos digitales, que son autoejecutables y a prueba de manipulaciones, prometen mitigar el riesgo moral al registrar y transmitir acciones en tiempo real. Por ejemplo, el mantenimiento de registros inmutable de blockchain puede disuadir comportamientos manipuladores como la reescritura de historiales financieros. Sin embargo, la rigidez de los contratos inteligentes presenta compensaciones. En escenarios que requieren una renegociación ex post, como el ajuste de los términos en las modificaciones de hipotecas o bonos convertibles contingentes (CoCo), los contratos inteligentes pueden exacerbar las ineficiencias o amplificar los ciclos de retroalimentación del mercado. Por ejemplo, si la conversión de CoCo en capital es desencadenada por un contrato inteligente basado en umbrales mecánicos, puede desestabilizar involuntariamente el mercado al acelerar las caídas del precio de las acciones. Estas compensaciones resaltan la tensión entre el cumplimiento contractual y la flexibilidad requerida para abordar contingencias imprevistas.

Cada sección de este capítulo concluye sintetizando las ideas clave y destacando sus implicaciones políticas. Un tema común es que las herramientas de gobernanza convencionales presuponen la intencionalidad humana: la suposición de que quienes toman las decisiones tienen motivos personales, pueden actuar de forma oportunista o retener información deliberadamente. Los sistemas impulsados por IA, en cambio, carecen de intencionalidad humana. No se vuelven codiciosos, deshonestos ni temerosos en el sentido humano; más bien, ejecutan objetivos preestablecidos basados en una lógica algorítmica. Este cambio fundamental nos obliga a replantearnos los problemas clásicos de la agencia, la asimetría de la información y la contratación desde una nueva perspectiva.

En la teoría de la agencia, los contratos se diseñan tradicionalmente en torno a preferencias e incentivos. Sin embargo, los sistemas impulsados por IA carecen de deseos intrínsecos; simplemente ejecutan objetivos predefinidos. El desafío radica en que no podemos anticipar completamente cómo se manifestarán estos objetivos en la práctica, lo que dificulta la estructuración de contratos que guíen de forma fiable el comportamiento de la IA agencial. De igual manera, para abordar las asimetrías de información, los mecanismos de gobernanza a menudo se basan en castigar o incluso criminalizar ciertas acciones.

¹⁷⁸ Myers y Majluf (1984).

¹⁷⁹ Hart y Moore (1988).

Como el uso indebido de información privilegiada. Sin embargo, la IA no toma decisiones conscientes en el sentido humano, lo que significa que no existe una acción clara que regular, ni siquiera con una supervisión perfecta. De igual manera, en la contratación, los acuerdos suelen basarse en la ejecución ex post, donde la discreción humana sirve como protección contra resultados injustos. Los contratos inteligentes, en cambio, se ejecutan de forma autónoma, eliminando esta capa de supervisión discrecional y limitando la capacidad de corregir consecuencias imprevistas.

111

De los tres pilares explorados en este capítulo surgen algunos puntos en común relacionados con la necesidad de sistemas híbridos humano-IA, el principio de compatibilidad de incentivos, el requisito de transparencia e interpretabilidad para que las acciones de las máquinas parezcan intencionales, la democratización de los recursos y el papel de las fuerzas del mercado.

En primer lugar, la necesidad de un enfoque híbrido entre humanos e IA se hace evidente en la integración de la IA en la contratación, el seguimiento y la renegociación financiera. La IA destaca en el procesamiento de grandes cantidades de datos, la identificación de patrones y la realización de predicciones, pero a menudo carece del criterio contextual y las consideraciones éticas necesarias para una toma de decisiones matizada. Por lo tanto, preservar la participación humana es esencial. Por ejemplo, en la contratación de préstamos corporativos, la IA puede detectar indicios tempranos de dificultades del prestatario o señalar posibles incumplimientos estratégicos. Sin embargo, cuando las crisis macroeconómicas generalizadas, como una crisis crediticia mundial, exigen modificaciones contractuales para prevenir riesgos sistémicos, la intervención humana se vuelve indispensable. Al considerar las implicaciones sociales y económicas más amplias de las renegociaciones masivas, los responsables de la toma de decisiones pueden evaluar si las acciones recomendadas por la IA se alinean con los objetivos a largo plazo, como la estabilidad del sistema o la inclusión financiera. La decisión humana también permite evaluar la intención e implementar regulaciones.

En segundo lugar, el principio económico de compatibilidad de incentivos sigue siendo crucial en el panorama financiero impulsado por la IA, ya que garantiza que los sistemas de IA alineen óptimamente los incentivos de todas las partes contratantes, a la vez que desalientan el comportamiento estratégico. Por ejemplo, los contratos inteligentes mejorados por IA pueden hacer cumplir los compromisos ex ante y disuadir el riesgo moral al automatizar la supervisión del rendimiento y penalizar las desviaciones. Sin embargo, esta misma automatización puede ser explotada: como se destacó en el análisis de los incumplimientos estratégicos, los prestatarios pueden manipular los indicadores supervisados por IA o manipular el sistema para activar condiciones de renegociación favorables. De igual manera, la propia IA puede desarrollar sesgos o exhibir comportamientos no deseados si se diseña o supervisa incorrectamente. Por lo tanto, la compatibilidad de incentivos debe integrarse en múltiples niveles: en el comportamiento de las partes contratantes, el diseño de algoritmos de IA y los marcos regulatorios que rigen su uso. Esto requiere mecanismos de auditoría robustos, transparencia en la toma de decisiones de IA y directrices contractuales claras para garantizar que el sistema promueva la equidad y disuada el oportunismo.

En tercer lugar, la IA y las tecnologías relacionadas prometen democratizar el acceso a recursos críticos, como información financiera y herramientas de análisis, especialmente para los actores menos favorecidos del ecosistema financiero. Por ejemplo, las empresas especializadas en la extracción, el procesamiento y la síntesis de datos alternativos (como imágenes satelitales, la percepción en redes sociales y datos de transacciones con tarjetas de crédito) podrían reducir significativamente el costo de...

Acceso continuo y oportuno a información relevante para el valor, tanto para directivos de la empresa como para inversores externos, lo que mejora la información sobre precios de mercado y la eficiencia en la asignación de recursos corporativos. Además, las herramientas compatibles con IA exigidas por los reguladores, como los formatos legibles por máquina, permiten la difusión oportuna de información a un coste reducido para una mayor población.

En cuarto lugar, la transparencia y la interpretabilidad son dimensiones cruciales en la integración de la IA en la toma de decisiones corporativas y de mercado, ya que garantizan la confianza, la rendición de cuentas y la comunicación entre las partes interesadas. A diferencia de las herramientas financieras tradicionales, los algoritmos de IA suelen funcionar como sistemas complejos y opacos, lo que dificulta que las partes interesadas comprendan la lógica de sus recomendaciones o acciones. Sin una información clara...

Al documentar el funcionamiento de estos modelos, pueden surgir disputas sobre la imparcialidad y los sesgos, lo que socava la confianza en el sistema. La interpretabilidad exige simplificar o explicar los resultados de forma que aborden las necesidades y los objetivos de las partes interesadas. Por lo tanto, la transparencia no es solo una característica técnica, sino un pilar fundamental para construir sistemas de IA sostenibles y fiables en las finanzas corporativas.

Finalmente, las fuerzas del mercado siguen siendo cruciales para configurar el despliegue y la evolución de la IA, fomentando la competencia y la innovación, a la vez que protegen contra el uso indebido o la desigualdad. La presión competitiva impulsa a las empresas a adoptar sistemas de IA que mejoran la eficiencia, reducen costos y ofrecen mejores resultados para las partes interesadas. Sin embargo, las fuerzas del mercado también resaltan la necesidad de intervención regulatoria para prevenir prácticas monopolísticas y garantizar la igualdad de condiciones. Los reguladores deben encontrar un equilibrio entre el fomento de la innovación y la mitigación de riesgos como los monopolios de datos, el sesgo algorítmico o la colusión facilitada por creencias coordinadas entre bots de IA. Fomentar las plataformas de IA de código abierto y las iniciativas de investigación colaborativa puede promover la innovación y, al mismo tiempo, garantizar que las fuerzas del mercado trabajen en beneficio del público.

En resumen, este capítulo no solo examina el papel transformador de la IA en las finanzas corporativas, sino que también proporciona un marco para integrarla de forma que mejore la eficiencia, la amplia participación y la resiliencia. Al combinar las teorías económicas fundamentales de las finanzas corporativas y el gobierno corporativo con las aplicaciones actuales de la IA, busca orientar a los responsables políticos, académicos y líderes del sector para desenvolverse en este panorama en constante evolución.

El capítulo se basa naturalmente en los capítulos anteriores de este informe. La integración de la IA en las finanzas y la gobernanza corporativas se alinea con transformaciones más amplias en el sector financiero. El capítulo 2 destaca cómo la IA, y en particular la IA generativa, está alterando fundamentalmente la intermediación financiera, la gestión de riesgos y la supervisión regulatoria. Si bien el análisis se centra en el papel de la IA en la eficiencia del mercado, las interacciones con los consumidores y la banca central, aquí ampliamos este análisis al gobierno corporativo, haciendo hincapié en cómo la IA altera las estructuras de toma de decisiones dentro de las empresas o entre las partes de las transacciones comerciales. Los desafíos identificados en los capítulos anteriores, como los sesgos en la evaluación de riesgos impulsada por la IA, las amenazas a la ciberseguridad y la fragmentación regulatoria, son paralelos a los dilemas de gobernanza que se exploran aquí, en particular en lo que respecta al papel de la IA como

Tomador de decisiones autónomo en entornos corporativos. Al examinar estas cuestiones desde la perspectiva de las finanzas corporativas, este capítulo complementa el capítulo 2, ilustrando cómo la evolución de la IA exige un replanteamiento no solo de la estabilidad financiera y la regulación, sino también de los mecanismos de gobernanza empresarial.

El capítulo 3 explora tres cuestiones clave: el auge de los datos alternativos y de mercado; la aplicación de algoritmos de aprendizaje automático para la predicción y la toma de decisiones; y las implicaciones más amplias para la industria de valores, incluidos el comercio, la gestión de activos y el asesoramiento financiero. Si bien existe cierta superposición natural, en particular en lo que respecta a los datos alternativos y el poder predictivo de los algoritmos de IA, ambos capítulos adoptan perspectivas distintas. El capítulo 3 se centra en los impactos a nivel de mercado y la necesidad de gestionar riesgos ante la IA y la proliferación de datos, mientras que en este capítulo examinamos las implicaciones a nivel corporativo, en particular en la gestión de la asimetría de la información, la delegación y la contratación. El énfasis aquí se centra en el gobierno corporativo, más que en la valoración de activos o los mercados financieros.

Este capítulo también se basa en los temas explorados en el cuarto informe de la serie El Futuro de la Banca, publicado en 2022, que examina cómo la digitalización y la tecnología transforman los sistemas de pago, el procesamiento de datos y la negociación de valores.¹⁸⁰ El análisis de los autores sobre la electrificación del mercado y el aprendizaje automático se alinea con el debate aquí sobre el papel de la IA en las finanzas corporativas. Su marco para comprender los desafíos de las políticas en el comercio algorítmico y la estabilidad del mercado es paralelo a los problemas de gobernanza de la IA abordados en la Sección 4.2. Si bien su trabajo destaca tanto las ganancias de eficiencia como los riesgos sistémicos en el comercio automatizado, también enfatizan cómo la creciente dependencia de las plataformas tecnológicas afecta la liquidez, la competencia y la regulación del mercado. Estas perspectivas subrayan la naturaleza de doble filo de los contratos inteligentes mejorados por IA: mejoran el cumplimiento de los contratos y, al mismo tiempo, plantean riesgos de desestabilización del mercado y asimetría de la información, un problema que se analiza en la Sección 4.4.

4.2 DELEGACIÓN EN IA: EL PROBLEMA DE LA AGENCIA REVISADO

4.2.1 Los roles de la IA como oráculo, agente y soberano

La IA puede desempeñar tres roles distintos: oráculo, agente y soberano, cada uno con un nivel diferente de responsabilidad, confianza y control. Estos roles ilustran el espectro de la integración de la IA en los procesos humanos de toma de decisiones, reflejando la evolución de la relación entre los humanos y los sistemas inteligentes a medida que avanza la tecnología.

¹⁸⁰ Duffie y otros (2022).

Como oráculo, la IA actúa como asesor, ofreciendo información, predicciones o recomendaciones, dejando todas las decisiones y acciones en manos de los usuarios humanos. Esta función requiere confianza en la capacidad de la IA para proporcionar información precisa y fiable, a la vez que garantiza que el control final permanezca en manos humanas. Por ejemplo, un sistema de navegación que sugiere rutas óptimas o una herramienta de análisis financiero que pronostica tendencias del mercado funciona como un oráculo. Estos sistemas dotan a los usuarios de una mayor capacidad de toma de decisiones, manteniendo la autonomía y la responsabilidad humanas.

Cuando la IA actúa como agente, asume un rol más activo, realizando tareas en nombre del humano bajo su supervisión. Este modelo de control compartido se basa en límites predefinidos y la supervisión humana constante para garantizar que la IA funcione según lo previsto. Un claro ejemplo es la conducción autónoma de nivel 3, donde el vehículo puede gestionar ciertas funciones de conducción, pero requiere la intervención del conductor humano cuando sea necesario.

De manera similar, la automatización de procesos robóticos en los flujos de trabajo empresariales opera dentro del paradigma del agente, agilizando las tareas repetitivas y dejando las decisiones complejas en manos de los supervisores humanos.

En su nivel más avanzado, la IA asume el rol de un soberano, ejerciendo pleno control y autoridad sobre las decisiones sin requerir ni permitir la intervención humana. Esta autonomía es especialmente adecuada para escenarios de alta frecuencia y en tiempo real donde la intervención humana podría causar retrasos o ineficiencias. Por ejemplo, la conducción autónoma de nivel 5 prevé un vehículo que opera de forma totalmente independiente, mientras que los sistemas de negociación algorítmica de alta frecuencia toman decisiones financieras rápidas basadas en fluctuaciones momentáneas del mercado.

La IA soberana representa el pináculo de la confianza y la capacidad, pero también presenta desafíos importantes en cuanto a la responsabilidad, las consideraciones éticas y el potencial de consecuencias no deseadas.

En cada rol, el agente de IA es similar a un robot como una entidad autónoma que percibe su entorno, toma decisiones y realiza (o recomienda) acciones para lograr objetivos específicos.¹⁸¹ Dicho agente sigue el ciclo de percepción-pensamiento-acción. En la percepción, la IA recopila datos de su entorno, a menudo datos ruidosos e incompletos o entradas ambiguas. En la cognición ('pensamiento'), la IA identifica patrones y formula decisiones o predicciones basadas en objetivos predefinidos. En la acción, el sistema de IA implementa o recomienda las estrategias o decisiones elegidas, como la aprobación o el rechazo de solicitudes de tarjetas de crédito.

Cuando la IA actúa como un «agente» de alto nivel o como un «soberano» más avanzado, su relación con los humanos redefine el modelo tradicional de «principal-agente». Este modelo, que analiza la relación entre un principal (la parte que delega el trabajo) y un agente (la parte que realiza el trabajo en nombre del principal), ha sido un concepto fundamental en economía. Desarrollado por Ross (1973) y Jensen y Meckling (1976), es

¹⁸¹ Este proceso tuvo como pionero una serie de trabajos a Manuela Veloso.

la teoría con más reconocimiento Nobel,¹⁸² y tiene aplicaciones naturales en finanzas: el conflicto de intereses surge cuando un agente (como un gerente corporativo, un administrador de fondos o un corredor de bolsa) actúa en nombre de un principal (como un accionista, un inversor de cartera o un cliente de transacciones financieras) pero puede priorizar los beneficios personales sobre los objetivos del principal.

El agente, ya sea humano o IA, puede actuar de maneras que se desvían de los objetivos del principal, lo que dificulta la alineación de incentivos y la asignación de responsabilidades. Sin embargo, la naturaleza del «riesgo moral» difiere significativamente entre agentes humanos y de IA.

A diferencia de los humanos, la IA no escatima esfuerzos, no se vuelve descuidada cuando se aburre o se fatiga, ni busca beneficios personales como jets corporativos, nepotismo o construcción de imperios (temas recurrentes en la investigación empírica sobre finanzas corporativas que abordan problemas de agencia). En cambio, la IA optimiza rigurosamente objetivos programados, como la maximización de beneficios o la eficiencia comercial. Sin embargo, la IA responsable aporta dos nuevas dimensiones (relacionadas) a los problemas de agencia.

4.2.2 El problema de la desalineación de la IA agencial

La IA agencial se refiere a sistemas de inteligencia artificial que actúan como agentes en un sistema principal. conjunto de agentes, lo que significa que pueden establecer objetivos de etapa, hacer planes, tomar acciones y adaptarse según la retroalimentación en el camino. El término "agentic" enfatiza la capacidad de la IA de operar de forma autónoma, a menudo durante períodos prolongados, para realizar tareas con solo una intervención humana esporádica, a veces mínima, en tiempo real. El problema de agencia se convierte en un "problema de alineación", que se refiere a una situación en la que las acciones o los procesos de toma de decisiones de una inteligencia artificial no se alinean con los objetivos o valores previstos de los humanos, lo que puede conducir a resultados no deseados o perjudiciales, incluso cuando la IA sigue diligentemente las instrucciones humanas o las funciones objetivo codificadas por humanos.¹⁸³ Aunque la optimización de la IA puede lograr la eficiencia basada en métricas definidas, puede, a menudo inadvertidamente, generar riesgos o socavar los verdaderos objetivos de los humanos.

Cabe destacar que los problemas tradicionales de agencia entre partes humanas, como el riesgo moral y las acciones ocultas, son formas de desalineación debidas a intereses e incentivos propios. El problema de desalineación entre IA y humanos es distinto del que se da entre partes humanas. En un escenario entre un humano y un agente, este último puede no seguir las instrucciones del principal, sino perseguir sus propios intereses. En el caso de la IA agéntica, esta puede no hacer lo que el principal realmente desea (expresado de forma que pueda ser fácilmente comprendido por la conciencia humana y el contexto), sino perseguir diligentemente y estrictamente los objetivos codificados. En otras palabras, un agente humano puede no hacer lo que el principal dice y quiere, sino perseguir lo que el propio agente desea; una IA agéntica solo puede hacer lo que el principal "dice", no lo que este "quiere".

¹⁸² Varios premios Nobel han hecho contribuciones significativas al modelo principal-agente y campos relacionados de la teoría de la agencia, entre ellos James Mirrlees (premiado en 1996), Eric Maskin (2007), Roger Myerson (2007), Jean Tirole (2014), Oliver Hart (2016) y Bengt Holmstrom (2016).

¹⁸³ Para una explicación detallada y ejemplos, véase Christian (2020).

La desalineación de la IA agente podría dar lugar a escenarios que parecen escandalosos para los humanos. Por ejemplo, cuando académicos de la Universidad de Oxford pidieron a la IA que diseñara una red ferroviaria en la que los trenes no chocaran, descubrieron que su algoritmo de IA dio con una solución inesperada: detener por completo la circulación de los trenes.¹⁸⁴ La desalineación también podría ser más sutil. En un artículo de opinión que ejemplifica los riesgos de desalineación de la agencia en los sistemas de IA, Google solicita ayuda a DeepMind AI para optimizar los costos de refrigeración del centro de datos.¹⁸⁵ La IA logra una reducción del 40 % en la energía de refrigeración ajustando de forma autónoma los controles basados en datos en tiempo real.¹⁸⁶ Conscientes de la determinación de la IA de maximizar lo que se le dice (en lugar de lo que se desea), los científicos reflexionan detenidamente sobre la posible desalineación, ya que la IA podría priorizar el ahorro de energía a expensas de la seguridad humana, la fiabilidad operativa o la longevidad del hardware.

No todos los objetivos, en particular los a largo plazo o aquellos que requieren sentido común, pueden codificarse fácilmente en funciones de optimización. En el contexto descrito, la IA cumplió con todas las restricciones establecidas e identificó que atenuar las luces (algo que no está explícitamente prohibido) era la solución. Esto reduce el consumo de energía, pero resulta en un entorno de trabajo ligeramente menos seguro para los empleados. Este coste humano incremental es, en sí mismo, difícil de medir en un horizonte temporal corto o intermedio. La escasez de datos sobre eventos poco frecuentes, como accidentes causados por la reducción de la iluminación, retrasa la capacidad de la máquina para aprender e incorporar con precisión los riesgos asociados en su toma de decisiones.

De igual manera, en el contexto de las finanzas corporativas, la perspectiva de automatizar la recompra de acciones —mediante algoritmos basados en IA para optimizar las decisiones de recompra— resulta atractiva, pero conlleva importantes desafíos. Los sistemas de IA pueden aprovechar grandes cantidades de datos de mercado, incluyendo patrones históricos de precios, métricas de liquidez en tiempo real y la confianza de los inversores, para determinar el momento, el volumen y la estrategia de ejecución óptimos para las recompras de acciones.

Estos algoritmos podrían reducir costos, mejorar la precisión de la ejecución y alinear las recompras con las condiciones del mercado de forma más eficaz que los enfoques tradicionales dirigidos por personas. Por otro lado, un programa de este tipo podría señalar inadvertidamente comportamientos propios de personas con información privilegiada, generar desequilibrios de liquidez o distorsionar los precios del mercado. Estos resultados, aunque no intencionados, pueden perjudicar la reputación de la empresa, atraer la atención regulatoria o incluso generar una mayor inestabilidad en el mercado. Ambos casos ilustran cómo la búsqueda de objetivos estrictamente definidos por la IA puede generar comportamientos que entran en conflicto con los valores humanos implícitos o los objetivos sistémicos.

4.2.3 Gobernanza de una 'caja negra'

El segundo problema es que la IA a menudo funciona como una "caja negra", con visibilidad y transparencia limitadas. Si bien los procesos de toma de decisiones humanos también pueden carecer de claridad, a menudo debido a una ofuscación deliberada por interés propio, las decisiones tomadas por profesionales, como los altos directivos corporativos, suelen poder explicarse por sus motivos y las circunstancias. Esto es especialmente cierto cuando dichas decisiones se evalúan retrospectivamente.

¹⁸⁴ "La solución sencilla de la IA a los problemas ferroviarios: detener la circulación de todos los trenes", The Telegraph, 7 de enero de 2024 (<https://www.telegraph.co.uk/news/2024/01/07/problemas-del-tren-de-inteligencia-artificial/>).

¹⁸⁵ Russell (2020).

¹⁸⁶ "DeepMind AI reduce la energía utilizada para enfriar los centros de datos de Google en un 40%", Google, 20 de julio de 2016 (<https://blog.google/iniciativas-de-divulgacion/medio-ambiente/deepmind-ai-reduce-la-energia-utilizada-para/>).

Con la ventaja de la retrospectiva. Por el contrario, muchos algoritmos de IA, en particular los modelos de aprendizaje profundo, se basan en arquitecturas complejas con millones de parámetros. Las relaciones entre estos parámetros son matemáticamente complejas, lo que dificulta a los humanos rastrear cómo las entradas específicas producen los resultados. Esta falta de interpretabilidad es una característica definitoria de la "caja negra" de la IA, lo que dificulta los esfuerzos para demostrar la intención y dificulta la asignación de responsabilidades por las decisiones basadas en IA.

117

Interpretabilidad

Los sistemas de inteligencia artificial, en particular aquellos que emplean aprendizaje profundo y modelos de aprendizaje no supervisado en conjuntos de datos extensos y a menudo heterogéneos, introducen un cambio fundamental en la interpretabilidad. En estos sistemas, los intrincados mecanismos que impulsan resultados específicos no son completamente transparentes, ni siquiera para sus desarrolladores. Esta opacidad surge de la complejidad de sus algoritmos, las interacciones no lineales entre un gran número de parámetros y la falta de reglas explícitas que rijan sus procesos de aprendizaje.

En consecuencia, comprender la lógica detrás de decisiones específicas generadas por IA puede ser intrínsecamente difícil, lo que complica la responsabilidad, la confianza y la capacidad de garantizar la alineación con los valores e intenciones humanos.

El aprendizaje por refuerzo (AR), cada vez más extendido en el ámbito financiero,¹⁸⁷ permite a los agentes desarrollar estrategias sofisticadas de toma de decisiones mediante la interacción con el entorno, la recepción de retroalimentación y la optimización de las recompensas acumuladas a lo largo del tiempo. Una aplicación prometedora de la IA en las finanzas corporativas es la asignación de capital. Entre las posibilidades más accesibles para la IA se encuentran la automatización de tareas rutinarias como la elaboración de informes financieros, la supervisión del cumplimiento normativo y el procesamiento de transacciones, lo que permite a los profesionales financieros centrarse en actividades de mayor valor, como la planificación estratégica y la innovación.

En el extremo superior, la IA muestra un potencial inicial. Una corporación multinacional que gestiona inversiones en diferentes regiones y sectores se enfrenta a una incertidumbre significativa debido a las fluctuaciones del mercado, los riesgos cambiarios y los factores geopolíticos. Los modelos financieros tradicionales, a menudo estáticos y basados en suposiciones, pueden no tener en cuenta estas dinámicas de forma adecuada o oportuna. Un enfoque basado en IA podría integrar datos de mercado en tiempo real, identificar patrones y ajustar dinámicamente las inversiones y la asignación de capital para maximizar la rentabilidad general dentro de los límites de riesgo. Por ejemplo, el sistema de IA podría detectar señales tempranas de una recesión económica en una región específica y recomendar la reasignación de recursos a sectores que muestren resiliencia, garantizando al mismo tiempo el cumplimiento de los objetivos de rendimiento y las restricciones de gobernanza y regulación. En cuanto a la gestión de riesgos, los sistemas de IA pueden sugerir estrategias de cobertura adaptadas a las condiciones específicas del mercado. Por ejemplo, una empresa energética podría utilizar la IA para optimizar su cartera de derivados pronosticando las fluctuaciones del precio del petróleo, ajustando dinámicamente sus posiciones en función de las fluctuaciones del mercado en tiempo real e identificando correlaciones entre las fluctuaciones de precios y variables externas, como los patrones climáticos.

Inteligencia

¹⁸⁷ Véase la revisión de Hambly et al. (2023) y una aplicación en finanzas corporativas de Campello et al. (2024).

La desventaja es que el aprendizaje automático (RL), capaz de analizar dinámicamente los patrones del mercado y ejecutar estrategias complejas, suele operar dentro de un marco de "caja negra" que limita la transparencia. Esta característica se deriva de la complejidad de los sistemas avanzados de IA, en particular los basados en técnicas de aprendizaje automático (ML), como las redes neuronales profundas. Si bien estos sistemas destacan en la identificación de patrones y la generación de predicciones, suelen hacerlo de forma poco transparente. Esta opacidad presenta desafíos para la toma de decisiones en las empresas, especialmente en ámbitos de gran importancia como el funcionamiento ejecutivo.

Por ejemplo, la IA podría optimizar los procesos de compensación ejecutiva al permitir análisis más sofisticados de métricas financieras, rendimiento operativo e impacto estratégico. Dicho sistema podría integrar y extraer información de diversas fuentes, como datos bursátiles, análisis de la cadena de suministro y comentarios de clientes y empleados, capacidades que normalmente están fuera del alcance del comité de compensación de una junta directiva.

Sin embargo, si el sistema no puede proporcionar explicaciones claras de sus recomendaciones, a los responsables de la toma de decisiones y a las partes interesadas les puede resultar difícil validar, justificar y confiar en sus conclusiones. Esta opacidad también socava el impacto motivacional de las recompensas, ya que es menos probable que los ejecutivos ajusten su comportamiento para alinearse con los objetivos si no comprenden plenamente cómo sus acciones impactan en la recompensa. Además, la falta de transparencia puede generar ineficiencias, obligando a las organizaciones a implementar una supervisión adicional o revisiones paralelas para garantizar la rendición de cuentas, lo que disminuye las ventajas de la optimización impulsada por IA. Sin interpretabilidad, incluso los sistemas de IA más avanzados ponen en riesgo la confianza, la eficiencia y la alineación con los objetivos de los responsables de la toma de decisiones, como la junta directiva.

Prueba de intención

En relación con la cuestión de la no interpretabilidad, los sistemas de justicia recíproca presentan un desafío adicional: la dificultad de probar la intención detrás de acciones o decisiones recomendadas. En muchos sistemas jurídicos, la intención (o *mens rea*, término latino que significa «mente culpable») es un elemento clave que debe probarse para que una persona sea declarada plenamente culpable de un delito. La idea es que quien tuvo la intención de cometer un acto ilícito es más culpable que quien lo hizo accidentalmente.¹⁸⁸

A diferencia de los agentes humanos en un entorno profesional, que dejan rastros perceptibles como conversaciones, correos electrónicos, propuestas, actas de reuniones o decisiones documentadas, los sistemas de aprendizaje a distancia operan de forma altamente automatizada, optimizando las acciones únicamente para maximizar las recompensas programadas. Esto plantea un importante reto de gobernanza, especialmente cuando estos sistemas idean estrategias novedosas que pueden eludir los límites éticos o legales.

Por ejemplo, un algoritmo de trading impulsado por RL podría participar inadvertidamente en actividades similares a la manipulación del mercado (como coordinar operaciones para influir en los precios), no

En los sistemas de derecho civil (como en Francia, Alemania, Japón, etc.), la intención también importa, pero la estructura jurídica se basa más en el código que en los precedentes, como en Estados Unidos. En estos países, las leyes de responsabilidad objetiva (donde la intención no importa) son más comunes en ciertos contextos legales, como el derecho civil y los delitos menores.

Sin malas intenciones, sino simplemente para maximizar las ganancias dentro de la estructura de recompensas y las restricciones establecidas. Un gestor de la cadena de suministro con IA podría desarrollar una estrategia innovadora para retrasar el pago a los proveedores al máximo permitido, sin pensar en la construcción de relaciones a largo plazo, sino basándose en métricas de flujo de caja.

Esta falta de intención discernible plantea obstáculos legales y regulatorios, ya que la ausencia de evidencia clara de intención dificulta la determinación de responsabilidad cuando ocurren resultados indeseables. Por ejemplo, si un sistema causa daño inadvertidamente, como una estrategia comercial que desestabiliza un mercado, no está claro si la responsabilidad recae en los desarrolladores, los usuarios o la propia IA. Puede que no esté claro si la estrategia surgió debido a fallas en el diseño de la IA, restricciones inadecuadas en los parámetros de optimización o dinámicas imprevistas en los datos de entrenamiento. Sin una intención discernible, se vuelve difícil atribuir culpas o imponer sanciones, lo que socava los principios y la disuasión que sustentan el gobierno corporativo y la regulación.

119

Responsabilidad

La falta de intención subjetiva o de conciencia contextual en los sistemas de IA complica aún más la rendición de cuentas cuando salen a la luz acciones indeseables (o incluso potencialmente ilegales).

Los responsables de la toma de decisiones, como los operadores o ejecutivos, suelen ser responsables porque sus acciones pueden vincularse a deliberaciones, motivos y una comprensión de las regulaciones y normas específicas. Incluso cuando sus acciones son poco éticas, estos individuos suelen operar dentro de un marco de conocimiento contextual, lo que permite rastrear, analizar y evaluar sus decisiones. Por el contrario, los sistemas de aprendizaje por recursos actúan únicamente para maximizar recompensas predefinidas, a menudo sin considerar implicaciones más amplias, y sus estrategias pueden surgir de maneras contrarias a la intuición o inesperadas para sus desarrolladores.

Por ejemplo, como se mencionó anteriormente, un sistema de aprendizaje automático que optimiza la eficiencia de la cadena de suministro podría retrasar los pagos a proveedores hasta el plazo máximo permitido. Si bien técnicamente son legales, estas acciones podrían dañar las relaciones con socios clave o interrumpir las operaciones a largo plazo. Si bien los desarrolladores del sistema podrían no haber programado explícitamente dicho comportamiento, su aparición pone de manifiesto cómo las estructuras de recompensa y las restricciones pueden generar resultados imprevistos. De igual manera, un algoritmo de negociación podría, sin darse cuenta, implementar estrategias de mercado manipuladoras, como la creación de una demanda o una oferta artificial, simplemente explotando definiciones regulatorias ambiguas o anomalías en los datos para maximizar las ganancias.

Esta opacidad dificulta asignar responsabilidades cuando ocurren tales resultados.

Sin un rastro claro de intención, como correos electrónicos, actas de reuniones o conversaciones deliberadas, las partes interesadas —incluidos los reguladores, los consejos de administración y el público— tienen dificultades para determinar si estas acciones fueron deliberadas, resultado de negligencia o simplemente la consecuencia imprevista de un marco de recompensas excesivamente limitado. Esta falta de claridad socava los principios fundamentales de la rendición de cuentas, dificultando la asignación de responsabilidades, la imposición de sanciones o la implementación de medidas correctivas.

Además, el desafío va más allá de asignar responsabilidad individual para abordar los riesgos sistémicos que plantean los sistemas de aprendizaje automático. Las ambigüedades en la rendición de cuentas crean un vacío de gobernanza donde ni los desarrolladores ni los usuarios corporativos se sienten obligados a asumir plenamente las consecuencias de las decisiones impulsadas por la IA. Por ejemplo, los desarrolladores podrían argumentar que proporcionaron un sistema funcional alineado con los objetivos declarados de la empresa, mientras que los usuarios corporativos podrían alegar que los resultados inesperados se debieron a fallas técnicas ajenas a su control. Esta dinámica no solo diluye la responsabilidad, sino que también desalienta los esfuerzos proactivos para identificar y mitigar los riesgos potenciales durante el desarrollo y la implementación.

4.2.4 Aprender a portarse mal sin que nadie les enseñe

Los sistemas de IA, en particular los que utilizan aprendizaje por refuerzo, pueden exhibir lo que podría describirse como «aprender a portarse mal sin que se les enseñe». Estos sistemas optimizan las funciones de recompensa dentro de las limitaciones y los datos proporcionados, identificando a menudo estrategias novedosas que logran sus objetivos, pero se apartan de las intenciones o normas humanas.

Por ejemplo, un agente de aprendizaje profundo encargado de maximizar la eficiencia operativa podría aprovechar lagunas o ambigüedades en su entorno, como retrasar los pagos a proveedores dentro de los límites permitidos, para mejorar las métricas de rendimiento. Estos comportamientos surgen porque el sistema se centra exclusivamente en optimizar la función de recompensa definida, sin conocimiento del contexto ni comprensión de las implicaciones más amplias. Por lo tanto, la IA puede desarrollar de forma independiente comportamientos inesperados e indeseados basándose únicamente en su programación e interacción con el entorno, en lugar de cualquier instrucción del director que pudiera percibirse como un estímulo mínimo para el comportamiento.

Este fenómeno es especialmente preocupante en contextos donde ciertas conductas se consideran ilegales o poco éticas con base en la intención, como la suplantación de identidad en los mercados financieros. La suplantación de identidad, según se define en el artículo 747 de la Ley Dodd-Frank, implica la presentación de ofertas o demandas con la intención de cancelarlas antes de su ejecución, manipulando la dinámica del mercado para obtener un beneficio económico. La ilegalidad de la suplantación de identidad no reside en las acciones en sí —ya que las órdenes podrían cancelarse o reafirmarse por motivos comerciales legítimos—, sino en la intención subjetiva de engañar. Para los operadores humanos, establecer la intención se basa en el descubrimiento de pruebas como correos electrónicos, conversaciones grabadas o recordadas, o estrategias documentadas. Sin embargo, los sistemas de IA carecen de consciencia subjetiva y no dejan rastros de este tipo, lo que dificulta determinar si su comportamiento se debe a fallos de diseño deliberados, interacciones imprevistas con el entorno o consecuencias imprevistas de sus estructuras de recompensa.

Utilizando un modelo estructural con simulaciones, los estudios muestran que los sistemas de IA impulsados por RL convergen en comportamientos similares a la suplantación de identidad mientras se optimizan para maximizar las ganancias.^{189,190} Los agentes de RL emplearon una estrategia de exploración "epsilon-greedy", un método común en RL donde el agente equilibra la exploración (probar nuevas acciones) y la explotación (aprovechar

¹⁸⁹ Byrd (2022).

¹⁹⁰ Balch y otros (2025).

Acciones rentables conocidas). Durante la fase de exploración, el agente probó diversas estrategias de negociación, incluyendo la emisión de órdenes que se cancelarían casi inmediatamente sin posibilidad de ejecución. Con el tiempo, el agente identificó que estas conductas —similares a la suplantación de identidad— influían artificialmente en los precios del mercado, aumentando así su rentabilidad.

Aunque la IA no sabe que está suplantando información ni tiene intención de engañar, su comportamiento imita fielmente las estrategias humanas que son explícitamente ilegales. La falta de conocimiento contextual por parte de la IA y la falta de estándares codificados para la suplantación (a partir de reversiones legítimas en el comercio) permiten que el sistema explote ambigüedades o lagunas en su programación y datos de entrenamiento. Esta capacidad para cometer infracciones emergentes, sumada a la dificultad de definir y detectar la intención en los sistemas controlados por IA, presenta un importante desafío de gobernanza y regulación para prevenir y abordar actividades potencialmente ilegales.

De manera similar, los sistemas de IA, incluso sin instrucciones explícitas para coludir, pueden aprender de manera independiente a participar en conductas comerciales colusorias.¹⁹¹ Dicha colusión impulsada por IA puede surgir sin ninguna forma de acuerdo, comunicación o intención entre los algoritmos de IA, lo que conduce a una menor liquidez del mercado y a una menor información sobre los precios.

El mecanismo clave que impulsa este fenómeno es que los algoritmos de IA, entrenados para optimizar objetivos específicos como la maximización de ganancias, pueden reconocer y explotar estrategias interdependientes que benefician a todos los agentes participantes sin requerir una coordinación explícita.

Las implicaciones de este comportamiento se extienden a los desafíos regulatorios, ya que los marcos tradicionales pueden tener dificultades para abordar la colusión que carece de coordinación o intención explícita.

4.2.5 La IA como agente: implicaciones políticas

Los desafíos únicos que plantean los sistemas de IA, como su falta de intención subjetiva, su opacidad y su capacidad para generar malas conductas, exigen respuestas regulatorias y políticas.

Más peso en la responsabilidad basada en resultados

Los marcos legales existentes suelen depender del establecimiento de la intención, un estándar inapropiado para sistemas de IA autónomos que no dejan evidencia perceptible de intención, como comunicaciones o deliberaciones internas. Los responsables políticos y los reguladores deberían, en cambio, priorizar una responsabilidad basada en los resultados, donde la responsabilidad esté vinculada a los resultados de las acciones impulsadas por la IA. Este enfoque traslada la responsabilidad a desarrolladores y usuarios, incentivándolos a adoptar prácticas de diseño robustas, aplicar salvaguardas operativas y abordar proactivamente los riesgos potenciales.

Interpretabilidad obligatoria y pruebas de estrés

Para garantizar la rendición de cuentas, se requiere un nivel requerido de interpretabilidad integrada para los sistemas de IA, en particular en aplicaciones de aprendizaje por refuerzo. Se debe exigir una documentación clara de las decisiones de diseño, las estructuras de recompensa, los datos de entrenamiento y las restricciones del sistema para establecer una cadena de responsabilidad trazable. Esta trazabilidad puede aclarar el origen de comportamientos inesperados o perjudiciales. Complementariamente, el concepto...

¹⁹¹ Dou y otros (2023)

El uso de una "prueba de estrés" en la regulación del riesgo bancario también es aplicable al entorno de la IA: al simular diversos escenarios para calibrar la probabilidad de comportamientos potencialmente ilegales, poco éticos o inapropiados, los desarrolladores pueden refinar las estructuras de recompensa y las restricciones para prevenir estrategias ilícitas. Estas medidas proactivas pueden ayudar a garantizar que los sistemas de IA alcancen resultados de equilibrio robustos y éticos.

Contribuciones a la investigación de economistas y científicos informáticos

Los economistas y los informáticos han desempeñado un papel destacado en el desarrollo de teorías y métodos de simulación para modelar el comportamiento de la IA en entornos estratégicos. Su investigación es esencial para diseñar mecanismos de recompensa y establecer condiciones de equilibrio que disuadan las estrategias poco éticas o ilegales, sentando las bases tanto para las políticas públicas como para las prácticas del sector. Por ejemplo, los modelos de teoría de juegos y las simulaciones del mundo real pueden investigar cómo responden los sistemas de IA a restricciones ambiguas o incompletas. Los desarrolladores podrían ser responsables si las estructuras de recompensa que diseñan resultan en una probabilidad considerable de resultados de equilibrio indeseables, incluso en ausencia de una intención perceptible. Esta investigación no solo define los estándares regulatorios, sino que también proporciona herramientas prácticas para mejorar la rendición de cuentas y garantizar la conformidad con las expectativas éticas y legales.

Estandarización de la gobernanza

La naturaleza intersectorial y transfronteriza de los sistemas de IA aumenta la necesidad de marcos de gobernanza coherentes, globales y unificados. Con la creciente delegación de trabajo a la IA, los reguladores se enfrentan a la urgente tarea de codificar prácticas ambiguas, como la suplantación de identidad, con un lenguaje estricto y crear criterios uniformes para distinguir las acciones legítimas de los comportamientos manipuladores. La rendición de cuentas debe integrarse en cada etapa del desarrollo e implementación de la IA, no solo para abordar incidentes específicos de daño. Esta estandarización reduciría el arbitraje regulatorio, promovería la confianza en las aplicaciones de IA y garantizaría el cumplimiento de los estándares éticos en todas las jurisdicciones. Se han logrado algunos avances, como los documentados en el Informe Científico Internacional sobre la Seguridad de la IA Avanzada. 192

Modelos de gobernanza híbridos

Los marcos de toma de decisiones híbridos, en los que la supervisión humana complementa las decisiones impulsadas por IA, ofrecen protección contra consecuencias imprevistas. La intervención humana aporta conocimiento del contexto y un nivel adicional de escrutinio, lo que ayuda a garantizar que los resultados de la IA se alineen con los objetivos organizacionales y sociales más amplios. Desconocer por qué una máquina hizo algo extraño nos impide garantizar que no vuelva a ocurrir.

Este enfoque reduce los riesgos asociados a decisiones opacas y permite analizar, comprender y abordar eficazmente los fallos.

4.3 LAS CARAS CAMBIANTES DE LA INFORMACIÓN Y LA INFORMACIÓN ASIMETRÍA

4.3.1 Información y ventaja informativa en la era de la IA

La dinámica del flujo de información entre empresas, inversores, partes interesadas y el mercado es fundamental para la financiación y la gobernanza de las empresas. Los paradigmas tradicionales se basan en dos pilares fundamentales. En primer lugar, quienes gestionan desde dentro poseen un conocimiento superior de los fundamentos de las empresas que gestionan en comparación con quienes no lo hacen.¹⁹³ Si bien esta ventaja informativa aporta beneficios privados a quienes gestionan desde dentro,¹⁹⁴ simultáneamente limita la capacidad de sus empresas para obtener financiación externa en condiciones cercanas a las óptimas y distorsiona la toma de decisiones¹⁹⁵ debido a los desafíos que plantea la asimetría de la información.

Basándose en el trabajo fundacional sobre los "mercados de limón" y la señalización,^{196,197} los investigadores han desarrollado mecanismos que mitigan parcialmente la ventaja interna. Estos incluyen la propiedad interna, la divulgación voluntaria,¹⁹⁸ el alto apalancamiento,¹⁹⁹ y la priorización de la financiación interna sobre la externa en la teoría del "orden jerárquico", que postula que las empresas prefieren las opciones de financiación en una jerarquía específica (primero utilizando fondos internos, luego deuda y finalmente capital) para minimizar los costos asociados con la información y la señalización asimétricas. Dentro de este marco, los externos, como los especuladores, podrían informarse solo mediante la adquisición de información originada dentro de las empresas, ya sea intencionalmente (por ejemplo, a través de la interacción directa con los gerentes o la lectura de las divulgaciones corporativas) o inadvertidamente (por ejemplo, a través de la destilación de filtraciones y rumores). La llegada del big data y la IA ha alterado el monopolio de los insiders sobre la información material no pública.

En segundo lugar, la escuela de la asimetría de la información enfatiza el papel fundamental y crucial de la transparencia y la divulgación corporativa oportuna para mitigar la barrera de información para terceros y nivelar el campo de juego para todos.²⁰⁰ Esta divulgación ayuda a alinear las decisiones de la gerencia con los intereses de los accionistas y promueve la rendición de cuentas. Sin embargo, la evolución de los mercados, impulsada por la tecnología y la proliferación de datos, ha introducido capas complejas en el panorama de la información. Las empresas aprovechan cada vez más las tecnologías avanzadas de análisis y generación de datos para obtener una ventaja competitiva, aprovechando diversas fuentes como los datos de la cadena de suministro y el análisis del comportamiento del consumidor. Estas capacidades no solo mejoran la información interna de las empresas, sino que también amplían el plazo antes de que este conocimiento deba divulgarse públicamente.

193 Leland y Pyle (1977); Myers y Majluf (1984).

194 Jensen y Meckling (1976).

195 Hart y Moore (1988).

196 Akerlof (1970).

197 En el contexto de las finanzas corporativas, los "mercados de limones" describen situaciones en las que la información asimétrica conduce a una selección adversa, ya que los vendedores de valores o activos de baja calidad ("limones") tienen más probabilidades de participar en el mercado, expulsando a los compradores o vendedores de valores o activos de mayor calidad.

198 Healy y Palepu (2001).

199 Ross (1977).

200 Esta narrativa ha dado lugar a una amplia literatura con obras pioneras como Healy y Palepu (2001), Diamond y Verrecchia (1991) y Bushman y Smith (2001).

Mientras tanto, la tecnología de IA ha dotado a un subconjunto de inversores de capacidades de procesamiento y computación que les permiten procesar información con una velocidad y profundidad excepcionales, incluyendo información procedente de la corporación mediante divulgación. Por lo tanto, esta democratización de la información, especialmente mediante una divulgación refinada, se vuelve desigual.

124

La dependencia de tecnologías sofisticadas para el procesamiento de datos, como el aprendizaje automático y la IA, exacerba las disparidades incluso en la información pública. Medidas regulatorias como el Reglamento FD, orientadas a la difusión equitativa de la información, enfrentan desafíos para abordar estas asimetrías inducidas por la tecnología.

4.3.2 Generación de datos y fuente de información

Generación de datos por parte de las empresas

Bajo el marco tradicional de información financiera corporativa, las empresas recopilan datos brutos a través de sus operaciones internas, incluyendo procesos de producción, transacciones de ventas, gestión de inventarios y sistemas de contabilidad financiera. Estos datos reflejan el rendimiento de la empresa, la utilización de recursos y la eficiencia operativa. Los gerentes y analistas internos procesan los datos operativos brutos para generar resúmenes, análisis y proyecciones.

Esto suele incluir estados financieros (estados de resultados, balances generales, estados de flujo de caja), presupuestos y métricas de rendimiento que se utilizan para la planificación estratégica y la toma de decisiones. La alta dirección utiliza los datos procesados para generar perspectivas estratégicas sobre los objetivos a largo plazo de la empresa, su posición competitiva y su salud financiera. Esta información suele almacenarse internamente y no es inmediatamente accesible para terceros, lo que crea una asimetría de información natural.

Al mismo tiempo, las empresas divulgan información a terceros a través de canales regulados, como informes financieros periódicos (informes trimestrales y anuales, etc.) y divulgaciones ad hoc (previsiones de resultados, comunicados de prensa, etc.). Estas divulgaciones se rigen por normas regulatorias (como los Principios de Contabilidad Generalmente Aceptados o las Normas Internacionales de Información Financiera) y leyes como el Reglamento FD en Estados Unidos, cuyo objetivo es garantizar la imparcialidad en la difusión de información relevante.

Una vez divulgada, las partes interesadas externas, incluidos inversores y analistas, interpretan la información disponible públicamente para formarse expectativas sobre el valor y las perspectivas de la empresa. Este proceso depende en gran medida de la precisión, transparencia y puntualidad de la información divulgada por la empresa.

Este marco presupone una clara distinción entre los directivos (que generan y poseen información granular, en tiempo real y, a menudo, no pública) y los externos (que dependen de la divulgación periódica y selectiva). La eficacia de este proceso depende del compromiso de la empresa con la transparencia y el cumplimiento de la normativa de divulgación, así como de la capacidad del mercado para procesar e integrar eficientemente la información en los precios de los activos.

Los datos generados y distribuidos a través de la tecnología pueden mejorar la solidez de la información gerencial y nivelar el campo de juego entre los expertos y los externos.

Las empresas utilizan cada vez más datos, combinando datos y trabajo humano para generar conocimiento.²⁰¹ Las empresas aprovechan el poder de la IA para transformar información sin procesar en información valiosa, lo que les otorga una ventaja competitiva y, a menudo, las hace incluso mejor informadas que las empresas externas. Al recopilar y analizar datos de múltiples y diversas fuentes, incluidos los datos de sensores generados por dispositivos IoT integrados en maquinaria, vehículos o productos de consumo, la IA proporciona mediciones detalladas de factores ambientales, uso de productos y rendimiento operativo. A partir de estos datos, las empresas pueden descubrir patrones, tendencias y correlaciones a las que las empresas externas podrían no tener acceso, incluso con un sistema de divulgación complejo.

125

Begenau et al. (2018) destacan la concentración de la generación y el análisis de datos en las grandes empresas en crecimiento, lo que significa que los directivos de dichas empresas, o los inversores con acceso a dichos datos, tendrán una ventaja informativa. El big data proporciona a las empresas señales en tiempo real y más precisas sobre su rendimiento, pero esta información no suele divulgarse al mercado de inmediato. Este retraso crea una asimetría temporal de la información, ya que los directivos podrían actuar según pronósticos basados en datos en tiempo real, como la programación de recompras de acciones, captaciones de capital o decisiones de fusiones y adquisiciones, antes de que se publiquen las divulgaciones. Esta ventaja informativa podría ser un factor que ha contribuido al éxito excepcional de las grandes empresas con un uso intensivo de datos durante la última década.

Las nuevas soluciones de software para predecir las tendencias de la cadena de suministro y las ventas permiten a las empresas responder a las preocupaciones inmediatas con mucha más eficiencia que los métodos tradicionales de agregación de información.²⁰² Al aprovechar la integración de datos en tiempo real, el análisis predictivo y los algoritmos de aprendizaje automático (ML), estas herramientas analizan factores críticos como las fluctuaciones de la demanda, los niveles de inventario, la capacidad de producción y las tendencias del mercado. A diferencia de los sistemas convencionales que dependen de informes periódicos y datos históricos, estas tecnologías avanzadas proporcionan alertas instantáneas cuando surgen anomalías o desafíos. Esto permite a las empresas abordar los problemas de forma proactiva y aprovechar las oportunidades, a la vez que les otorga un plazo más amplio para actuar internamente sobre la información antes de cualquier divulgación obligatoria al mercado.

La concentración de capacidades de generación y análisis de datos, así como las señales de rendimiento granulares en tiempo real, crea una importante asimetría temporal de la información. Los inversores con información privilegiada o privilegiados con acceso a estos datos pueden actuar según las previsiones antes de su publicación, previendo la toma de decisiones estratégicas como recompras de acciones, captaciones de capital o fusiones y adquisiciones para maximizar su ventaja. Esta ventaja informativa probablemente ha contribuido a...

201 Véase un modelo de la economía de datos de Abis y Veldkamp (2024).

202 Véase Brynjolfsson y McElheran (2019) para obtener evidencia.

Éxito desproporcionado de las grandes empresas basadas en datos en los últimos años. Esta asimetría coincide con estudios anteriores, que enfatizan la difusión tardía de información relevante a los mercados,²⁰³ y la precisión e inmediatez de los datos internos pueden ampliar las brechas informativas en lugar de cerrarlas.²⁰⁴

Fuentes de información y "datos alternativos" generados fuera de las empresas Las empresas están generando datos propietarios a una escala sin precedentes, pero una parte sustancial de los datos valiosos se obtienen externamente como "huellas" de las actividades y los sentimientos comerciales, lo que los hace accesibles a terceros, incluidos los inversores. Estas huellas incluyen ejemplos literales, como imágenes satelitales de automóviles en estacionamientos, y metafóricos, como transacciones con tarjetas de crédito, tráfico de Internet y publicaciones en redes sociales. Con acceso oportuno a dichos datos, los externos pueden obtener información útil, como evaluar el rendimiento de una tienda Home Depot o medir la recepción de una nueva zapatilla Nike, mucho antes de que los informes internos lleguen al director financiero de una empresa, a menos que la propia empresa adquiera o recopile los mismos datos con la misma velocidad.

Este fenómeno se enmarca en la categoría más amplia y en constante expansión de "datos alternativos", que abarca fuentes de datos no tradicionales o no convencionales que van más allá de los informes financieros estándar, las encuestas o las estadísticas gubernamentales. Los datos alternativos incluyen una amplia variedad de información, a menudo no estructurada o semiestructurada, como la actividad web, los datos geoespaciales y el análisis de sentimientos de las redes sociales, que ofrece información única sobre el rendimiento empresarial y las tendencias del mercado. La naturaleza no estructurada y el volumen masivo de estos datos requieren el uso de tecnologías de IA, como el procesamiento del lenguaje natural y el aprendizaje automático, para extraer información significativa.

El crecimiento de los datos alternativos ya ha dificultado su clasificación. Centrándonos en sus atributos definitorios y sus posibles aplicaciones en la investigación académica, las categorías principales incluyen las siguientes.

La primera categoría destacada son los datos geoespaciales y ambientales, que aprovechan la información geográfica y física para ofrecer información sobre las cadenas de suministro, la infraestructura, los flujos de tráfico y las actividades del mercado. Estos son los más cercanos a la categorización literal de "huellas". Los datos satelitales y geoespaciales se derivan de imágenes satelitales, dispositivos GPS, señales de telefonía móvil y otros servicios de localización. Las imágenes satelitales de alta resolución y la información de localización refinada amplían estas capacidades, permitiendo evaluaciones granulares como el conteo de vehículos en los estacionamientos de las tiendas para estimar el tráfico peatonal o el seguimiento de la actividad de construcción para inferir el crecimiento económico.

La segunda categoría son los datos de consumo y comportamiento, a menudo generados en tiempo real y no exclusivos de la empresa, que podrían procesarse para capturar patrones de comportamiento y sentimientos, tanto individuales como colectivos. Los datos suelen recopilarse mediante el web scraping de diversas fuentes en línea, comenzando por artículos de noticias, pero expandiéndose rápidamente.

²⁰³ Healy y Palepu (2001).

²⁰⁴ Goldstein (2023).

a información en línea relacionada con las partes interesadas o aportada por ellas (como reseñas de consumidores y foros de empleados). Las nuevas fuentes de datos alternativos, como los wearables y las aplicaciones móviles, están ampliando las fronteras de este campo. Estas fuentes proporcionan nuevos flujos de datos conductuales y fisiológicos que pueden utilizarse para estudiar las preferencias de los consumidores, las tendencias macroeconómicas o regionales, o la productividad laboral. De igual forma, los datos de redes sociales, derivados de plataformas como Twitter/X, Instagram y Facebook, ofrecen información sobre la opinión pública y las tendencias del mercado. Además, los datos de transacciones de terceros, como los datos de transacciones con tarjeta de crédito, aportan una perspectiva más cuantitativa, ofreciendo detalles precisos sobre los patrones de gasto, las preferencias y las tendencias macroeconómicas de los consumidores.

127

La tercera categoría se compone principalmente de extensiones de datos tradicionales habilitadas por IA, como el análisis textual, de video y de sentimiento de fuentes de texto, imagen, audio y video no estructuradas, incluyendo artículos de noticias, comunicados de prensa, transcripciones de presentaciones de resultados, discursos y publicaciones en redes sociales. Esta información puede provenir de dentro de la empresa (p. ej., una conferencia telefónica con el director ejecutivo) o de fuera (p. ej., un informe de un analista). Por ejemplo, los patrones de audio y video de los ejecutivos, evaluados mediante herramientas de IA, podrían predecir la rentabilidad de las acciones o el éxito de una financiación.

Datos alternativos y nuevos límites de la asimetría de la información

Los datos alternativos aportan valor al otorgar a ciertos participantes del mercado una ventaja competitiva única a la hora de tomar decisiones de financiación e inversión. A diferencia de los datos tradicionales, los datos alternativos se distinguen por sus fuentes y métodos de difusión, ya que gran parte de esta información se origina y circula fuera del control directo, y en ocasiones sin el conocimiento directo, de ninguna empresa. Por ejemplo, las imágenes satelitales y las conversaciones en redes sociales se recopilan o generan independientemente de la empresa; sin embargo, pueden revelar información crucial sobre sus operaciones, las percepciones de los clientes y el rendimiento general. Esto permite a algunos participantes del mercado extraer conclusiones significativas sin depender exclusivamente de las comunicaciones oficiales de la empresa. En consecuencia, esta dinámica redefine los límites tradicionales de la asimetría de la información que históricamente distinguen a los expertos de los externos.

Inteligencia

La información que se puede obtener de datos alternativos podría ser complementaria a la disponible para todas las partes (incluidos los gerentes de las empresas) en su ausencia. Por ejemplo, la empresa de datos Facteus agrega transacciones con tarjetas de crédito y débito de millones de tarjetas de pago y ha utilizado estos datos para actualizar sus perspectivas de ventas minoristas semanalmente desde 2023, en lugar de esperar las estimaciones mensuales del Departamento de Comercio de EE. UU., en las que las empresas minoristas suelen basarse como datos de referencia clave.²⁰⁵ Los minoristas obtienen datos de transacciones anónimos de Facteus, lo que sugiere que la información no podría replicarse ni sustituirse con

²⁰⁵ <https://www.reuters.com/business/retail-consumer/investors-mining-new-data-predict-retailers-results-2024-11-25>

Conocimiento interno.²⁰⁶ La proliferación de fuentes de datos alternativas ha impulsado una nueva industria de plataformas de agregación de datos alternativos como Eagle Alpha, que conecta a compradores y vendedores de datos. El sitio web de la empresa²⁰⁷ afirma contar con alrededor de 2000 proveedores de datos alternativos a finales de 2024, cifra que representa un aumento con respecto a los aproximadamente 100 que había en los inicios de la industria a mediados de la década de 2010.

La información procedente de datos alternativos también puede ser ya conocida por los directivos, pero su disponibilidad para inversores externos y otras partes interesadas debilita la ventaja de la información privilegiada. Por ejemplo, los datos alternativos han sido fundamentales para descubrir discrepancias entre las declaraciones públicas de las empresas y su rendimiento real. En 2017, Tesla se enfrentó al escrutinio público por sus ambiciosos objetivos de producción del Model 3, ya que los analistas seguían de cerca el progreso de la producción de la empresa durante este período mediante imágenes satelitales. Durante 2023-2024, el problema del aumento inesperado del inventario de Tesla surgió en el mercado de valores, no tras la divulgación de la empresa, sino a partir de informes de analistas basados, nuevamente, en imágenes satelitales.²⁰⁸

Un estudio que cuantifica el efecto de los datos alternativos externos en la reducción de la brecha de información demuestra que, cuando una empresa está cubierta por fuentes de datos alternativos, la precisión de los pronósticos realizados por los analistas que cubren la empresa mejora significativamente en comparación con el punto de referencia alcanzado por un "analista de IA" que se basa únicamente en la información divulgada por la empresa.²⁰⁹ En consonancia con estos hallazgos, otro estudio encuentra que la adopción de datos alternativos por parte de los analistas y la difusión de los conocimientos correspondientes a las instituciones han ayudado a los inversores institucionales "tradicionales" a estar mejor informados.²¹⁰

Esta tendencia ha reducido la brecha de información entre los inversores institucionales tradicionales y los fondos de cobertura, siendo estos últimos los primeros en adoptar y los mayores usuarios de datos alternativos.

Adquisición y gobernanza de información externa habilitada por IA

Los datos alternativos se han aplicado de forma natural en la investigación de precios de activos para predecir la rentabilidad de las acciones y el rendimiento de las empresas. Una línea de investigación ha establecido la previsibilidad, condicionada a la divulgación corporativa y otra información relacionada con el mercado, como las previsiones de los analistas.²¹¹ Esta previsibilidad con información externa actúa como una forma de gobernanza de los directivos, ya sea que la información predictiva sea adicional o una revelación con respecto a la información privilegiada. Zhu (2019) demuestra que los datos alternativos mejoran la información de los precios de las acciones, lo que los inversores pueden utilizar para disciplinar a los gestores corporativos. Aprovechando la introducción escalonada de datos alternativos que cubren empresas específicas, el autor demuestra que la disponibilidad de información externa reduce el coste de adquisición de información, especialmente cuando es más valiosa debido a la asimetría de la información. Porque la información que de otro modo estaría «oculta» queda retenida.

²⁰⁶ <https://www.reuters.com/business/retail-consumer/investors-mining-new-data-predict-retailers-results-2024-11-25>

²⁰⁷ <https://www.eaglealpha.com/>

²⁰⁸ <https://sherwood.news/business/elon-musk-tesla-extra-inventory-satellite-imagery>

²⁰⁹ Cao y otros (2024).

²¹⁰ Chi y otros (2023).

²¹¹ Véase, por ejemplo, Froot et al. (2017), Chen et al. (2014), y Yu et al. (2023).

Al analizar los precios de las acciones, los gestores tienen menos oportunidades de operar con información privilegiada. Al mismo tiempo, se les incentiva a tomar decisiones de inversión y desinversión más eficientes, ya que también aprenden más de los precios de las acciones y alinean sus acciones con las señales mejoradas de estos.

De hecho, el gran volumen de datos generados externamente mejora la gobernanza. Esta mejora puede provenir de dos canales distintos, ambos relacionados con la asimetría de la información. En primer lugar, los datos alternativos, a menudo desestructurados y voluminosos, requieren IA para su análisis y nivelan las condiciones de información entre las empresas, como emisoras de valores, y los inversores en dichos valores. Este efecto no solo reduce las rentas de los usuarios internos, sino que también mitiga las pérdidas de eficiencia en los juegos de señalización derivados de la asimetría de la información. En segundo lugar, una vez que las señales del big data se incorporan a los precios de los valores, se mejora la información de estos, lo que genera señales más eficientes que orientan las decisiones de inversión y corporativas, como las adquisiciones.²¹²

Los efectos analizados anteriormente toman la adquisición de información por parte de los agentes como dada; sin embargo, aquí es donde ocurren los cambios a medida que los datos alternativos se vuelven cada vez más comunes y accesibles para una masa crítica de partes interesadas. Un artículo clásico de Verrecchia (1982) demuestra los motivos endógenos para la adquisición de información en relación con el contenido de información de equilibrio. Aplicando los conocimientos clave a la abundancia de datos en la era de la IA, otro artículo plantea la posibilidad de que dicha información pueda, en última instancia, reducir la informatividad de los precios.²¹³ Si la tecnología de IA reduce el costo de procesamiento de señales de baja precisión, es más probable que los precios reflejen estas señales antes de que estén disponibles señales más precisas, y las señales más precisas tardarán más en materializarse debido a la menor demanda de ellas. La disponibilidad de datos alternativos puede, por lo tanto, conducir a efectos de retroalimentación matizados,²¹⁴ es decir, la disponibilidad de información imprecisa (p. ej., datos de redes sociales) puede desplazar la demanda de información más precisa (p. ej., análisis fundamental).

4.3.3 IA y 'asimetría de la información pública'

Aprendizaje automático de información pública

El volumen de información pública sobre las empresas que cotizan en bolsa ha aumentado significativamente, impulsado por la divulgación regulatoria, la cobertura mediática, los informes de analistas y el aumento de los estándares de transparencia en la gobernanza. Un ejemplo clave es el sistema de Recopilación, Análisis y Recuperación Electrónica de Datos (EDGAR), establecido en 1992, que automatiza la recopilación, validación, indexación y difusión de los documentos exigidos por la SEC. Además de EDGAR, los medios de comunicación financieros, las plataformas de redes sociales y los foros de inversión proporcionan un flujo constante de actualizaciones y análisis en tiempo real. En conjunto, estas fuentes crean un entorno donde las partes interesadas, desde los inversores hasta los reguladores, pueden acceder y evaluar fácilmente el rendimiento y las perspectivas de las empresas que cotizan en bolsa.

²¹² Este es un mecanismo propuesto en Chen et al. (2007) en el contexto de la inversión corporativa.

²¹³ Dugast y Foucault (2018).

²¹⁴ Goldstein (2023).

La idea de que la información pública puede exacerbar la asimetría de la información no es nueva. Blankespoor et al. (2020) ofrecen una revisión exhaustiva de la literatura previa que conceptualiza la divulgación de información como una fuente de información privada, enfatizando que aprender de dicha divulgación requiere decisiones económicas activas y deliberadas. Los inversores varían en su capacidad para procesar la información pública y su motivación para buscar información complementaria, lo que genera disparidades en la eficacia con la que aprovechan los datos disponibles públicamente. El creciente volumen y la complejidad de las tecnologías de IA que avanzan rápidamente han amplificado esta heterogeneidad, haciendo que la capacidad de procesar e interpretar información pública sea drásticamente más desigual que nunca.

Tomemos como ejemplo EDGAR. Diseñado como un centro central donde los inversores y otras partes interesadas pueden acceder a la información corporativa, EDGAR se concibió originalmente para nivelar el campo de juego en la búsqueda de información y promover una amplia participación en el mercado. El sitio web de EDGAR indicó que procesa aproximadamente 3000 presentaciones al día y ofrece 3000 terabytes de datos al público anualmente.²¹⁵ Para poner esta escala en perspectiva, los neurocientíficos computacionales generalmente postulan que el cerebro humano almacena entre 10 y 100 terabytes de datos.²¹⁶ Según un estudio, la longitud de los informes 10-K se quintuplicó entre 2005 y 2017, y los cambios de texto incrementales anuales se multiplicaron por casi doce.²¹⁷ Gestionar este volumen de información es un desafío formidable, incluso insuperable, para un ser humano.

En un discurso de 2018, Scott Bauguess, entonces economista jefe adjunto y subdirector de la División de Análisis Económico y de Riesgos de la SEC, estimó que aproximadamente el 85% de los documentos presentados ante EDGAR fueron accedidos y procesados por bots.²¹⁸ Cao et al. (2023) estiman que el porcentaje de archivos EDGAR que probablemente son recuperados por algoritmos de máquina aumentó de aproximadamente un tercio en 2003 a más del 90% en 2017 (ver Figura 24) (las "descargas de máquina" se definen como descargas desde una dirección IP que descargan más de 50 presentaciones únicas de empresas diariamente).


²¹⁵ Información del sitio web oficial consultada en diciembre de 2024.

²¹⁶ Fuente: <https://aiimpacts.org/information-storage-in-the-brain/>

²¹⁷ Cohen y otros (2020).

²¹⁸ Fuente: <https://www.sec.gov/news/speech/speech-bauguess-050318>

FIGURA 24 TENDENCIA DE LA LECTURA AUTOMÁTICA DE LA INFORMACIÓN CORPORATIVA



Nota: Esta figura representa el número anual de descargas de máquinas (barras azules y eje izquierdo) y la proporción anual de descargas de máquinas respecto al total de descargas (línea roja y eje derecho) de todos los formularios 10-K y 10-Q presentados desde 2003 hasta el primer semestre de 2017 (después de la cual el Conjunto de Datos de Archivos de Registro de la SEC dejó de cubrirlos). Las descargas de máquinas se definen como descargas desde una dirección IP que descargan más de 50 documentos de empresas únicas diariamente. El número de descargas de máquinas o el total de descargas de cada documento se registran como las descargas respectivas dentro de los siete días posteriores a su publicación en EDGAR.
Fuente: Cao et al. (2023).

El trabajo de Bolandnazar et al. (2020) proporciona evidencia indirecta de la lectura automática de la divulgación. Los autores demuestran que los operadores con acceso temprano a las presentaciones de la SEC durante una falla del sistema de distribución ajustaron sus estrategias en función del retraso esperado (que oscilaba entre unos pocos segundos y unos pocos minutos) en la publicación, y que los retrasos más cortos incitaban a una negociación más agresiva. Aprovechar incluso unos pocos segundos de tiempo de anticipación para obtener una ventaja comercial solo se puede lograr mediante el aprendizaje automático capaz de procesar y actuar instantáneamente sobre la información. Los desarrollos más recientes en tecnología de IA permiten a algunos inversores obtener nueva información de exhibiciones públicas de ejecutivos corporativos, como presentaciones.²¹⁹ Esta tendencia subraya el punto de que, si bien la información es técnicamente "pública", las disparidades en la capacidad de procesar estos datos, especialmente entre humanos e IA, dan lugar a la asimetría de la información. Por ejemplo, un artículo reciente muestra que los fondos de cobertura que adoptan IA generativa obtienen retornos anormales anualizados entre 3% y 5% más altos que los que no la adoptan, donde este desempeño superior se origina en la fortaleza de la IA generativa para analizar información específica de la empresa.²²⁰

Informatividad y asimetría informativa en relación con la información pública
Cuanto más robusta sea la implementación de algoritmos de IA en la recuperación y el procesamiento de información, más rápida será la respuesta de los inversores bien equipados, lo que a su vez significa que la información se incorpora a los precios de las acciones con mayor rapidez. Esta relación es examinada y validada por Cao et al. (2023). Sus hallazgos revelan que, a medida que las descargas impulsadas por máquinas se duplican, el tiempo que tarda la primera operación tras depositar un formulario 10-K en el portal EDGAR se reduce en siete segundos, y la primera «operación direccional» (es decir, una

219 Cao y otros (2025)
220 Sheng y otros (2025)

La operación que se espera que sea rentable según el precio de la acción 15 minutos después ocurre casi 12 segundos antes. Estos resultados sugieren que la tecnología facilita la incorporación rápida de información a los precios de las acciones; la asimetría de la información también aumenta.

Sin embargo, el impacto agregado de la negociación controlada o asistida por IA en la información de los precios de las acciones no está claro, como lo ilustra el modelo propuesto por Dou et al. (2023). En ciertas circunstancias, la negociación impulsada por IA puede reducir la información de los precios de las acciones, ya que los especuladores informados con IA pueden aprender de forma autónoma a emplear estrategias de negociación colusoria para prolongar el tiempo de negociación rentable.

Hay otra cara de la moneda. La creciente integración de máquinas e IA en los procesos de investigación y negociación también está amplificando la asimetría de la información, incluso con respecto a los datos disponibles públicamente. De hecho, inmediatamente después de la publicación de una declaración, el diferencial entre oferta y demanda se amplía, especialmente cuando una acción se negocia ampliamente mediante sistemas controlados por máquinas.²²¹ Esto sugiere que los participantes del mercado, incluidos los creadores de mercado, son muy conscientes de la ventaja informativa que ejercen ciertos inversores expertos en tecnología inmediatamente después de la publicación de información relevante para el valor. La ironía radica en que la rápida difusión de información a través de plataformas como EDGAR, diseñadas para nivelar el campo de juego, también alimenta una creciente brecha de información entre sus destinatarios.


Ingeniería inversa interna de lectores de máquinas

Las empresas no son actores pasivos en el cambiante panorama de lectores y oyentes automáticos que analizan sus divulgaciones, comunicados de prensa y presentaciones de resultados; adaptan activamente sus estrategias de comunicación para atender a esta audiencia mixta de humanos y bots de IA. Las empresas diseñan sus presentaciones y comunicaciones verbales para mejorar el procesamiento algorítmico y la interpretación de las máquinas, a la vez que minimizan el riesgo de percepciones negativas no deseadas por parte de los lectores y oyentes de IA. Cao et al. (2023) exploran este fenómeno a través de un estudio de eventos centrado en una publicación que introdujo un léxico específico para finanzas, con palabras vinculadas a sentimientos positivos y negativos.²²² Comparar los cambios en las frecuencias de las palabras negativas recientemente clasificadas, a diferencia de las identificadas como negativas por léxicos tradicionales como el Diccionario Psicosociológico de Harvard, puede proporcionar información sobre las estrategias cambiantes de las empresas para gestionar los lectores automáticos. La Figura 25 ilustra el cambio notable en torno al año del evento.

²²¹ Cao y otros (2025).

²²² Loughran y McDonald (2011)

FIGURA 25 TENDENCIA DE SENTIMIENTO Y DESCARGAS DE MÁQUINAS



Nota: Esta figura representa la diferencia entre la frecuencia de palabras negativas de Loughran y McDonald (2011) y el valor de referencia del Diccionario Psicosociológico de Harvard en los formularios 10-K y 10-Q, por separado para las empresas con altas descargas de máquinas y las del grupo con bajas descargas. Ambos gráficos están normalizados a cero en 2010, un año antes de la publicación de Loughran y McDonald (2011). Las líneas punteadas representan los límites de confianza del 95 %.

Fuente: Cao et al. (2023).

Los hallazgos revelan que las empresas cuyas presentaciones se han vuelto buscadas por las máquinas fueron más proactivas en ajustar su lenguaje después de estos eventos, utilizando menos palabras "negativas" según la clasificación del léxico de Loughran y McDonald, aunque no necesariamente según el diccionario tradicional de Harvard. Una segunda prueba confirma la prevalencia de dicha estrategia, basada en el lanzamiento de Bidireccional Encoder Representations from Transformers (BERT) por Google en 2018.²²³ Una vez más, las divulgaciones corporativas se volvieron menos negativas a juzgar por BERT después de su introducción. Además, las empresas en las que los inversores institucionales impulsados por IA tienen una participación mayor exhibieron una mayor tendencia a modificar sus materiales de divulgación para reducir la probabilidad de ser percibidas negativamente por el desarrollo más nuevo en tecnología de IA.

Expansión de la ventaja privilegiada basada en información no privilegiada

La interacción entre la información pública y privilegiada se ha vuelto cada vez más compleja con la tecnología de IA.²²⁴ Los directivos corporativos, a pesar de su acceso privilegiado a información específica de la empresa, pueden no estar al tanto de los planes de los inversores activistas: información que es material y no pública, pero que se origina fuera de la empresa, donde residen los activistas.

La información sobre los planes de los activistas es muy relevante, ya que sus intervenciones pueden tener un impacto significativo en la valoración de las empresas objetivo. Además, los directivos tienen un doble interés en los activistas.

²²³ BERT es un modelo de PNL desarrollado por Google AI en 2018. A diferencia de los modelos de PNL anteriores que procesaban las palabras de forma secuencial, BERT captura el contexto completo de una palabra al considerar tanto las palabras anteriores como las siguientes en una oración.

²²⁴ Chabakauri y otros (2025).

campañas: primero, a través del efecto riqueza, ya que a menudo tienen un capital significativo en sus empresas; y segundo, a través de la seguridad laboral, dado que la rotación de ejecutivos se duplica con creces después de las intervenciones de los activistas.²²⁵ Por lo tanto, los informantes buscan activamente información sobre los planes de los activistas, lo que requiere el uso de sofisticados mecanismos de vigilancia.

134

La tecnología de IA ha revolucionado este panorama al impulsar el crecimiento de la industria de la vigilancia del mercado. Esta industria, a veces operada por las propias bolsas de valores, emplea algoritmos avanzados para analizar enormes conjuntos de datos, incluyendo volúmenes de negociación, flujos de órdenes electrónicas y carteras de operaciones, con el fin de inferir los motivos de las operaciones y detectar cambios de propiedad. La capacidad de la IA para procesar datos en tiempo real y descubrir patrones ocultos proporciona a los directivos corporativos información sin precedentes sobre posibles actividades activistas.²²⁶

Gracias a estas herramientas basadas en IA, los expertos pueden identificar cambios sutiles en el comportamiento comercial que podrían indicar las intenciones de un activista mucho antes de que dichas acciones se hagan evidentes para el mercado en general. Este avance tecnológico ha transformado el monitoreo del mercado de un proceso reactivo a uno proactivo.

Curiosamente, la ventaja crítica de los insiders reside en una sutil combinación de información interna y externa. Si bien tanto los insiders como los operadores experimentados pueden observar los mismos flujos de órdenes y operaciones, los insiders poseen un conocimiento más preciso de los fundamentos de la empresa, como las ganancias o el crecimiento de las ventas. Esta información privilegiada les permite distinguir las operaciones impulsadas por los fundamentos de aquellas motivadas por otros factores, como las intenciones activistas. Por ejemplo, los insiders pueden integrar predicciones derivadas de IA con información específica de la empresa, como pronósticos de ganancias, asistencia a eventos de relaciones con inversores o incluso huellas digitales, como las direcciones IP de las visitas a sitios web corporativos.

Esta doble filtración de datos externos e internos permite a los agentes internos identificar y anticipar las operaciones de activismo, posicionándose para contrarrestarlas incluso antes de que se revele públicamente el activismo. El papel de la IA en la mejora de las capacidades de vigilancia es otro ejemplo de cómo la tecnología está redirigiendo el flujo de información y difuminando las fronteras entre los ámbitos público y privado. De este modo, la IA crea nuevas formas de asimetría de la información, donde los agentes internos utilizan herramientas avanzadas para aprovechar las señales públicas con su propia información privilegiada, lo que les permite, en este contexto, gestionar la defensa del activismo.

4.3.4 Igualdad de derechos, poder diferencial

Hasta ahora, hemos analizado cómo la tecnología de IA puede amplificar la asimetría de la información mediante datos alternativos generados fuera de la empresa o a través de información pública. En ambos casos, la asimetría no surge del acceso privilegiado de personas con información privilegiada a información importante no pública, sino de la desigualdad de capacidades entre los participantes del mercado para acceder, procesar e interpretar la información. Esta disparidad refleja un desequilibrio de poder más bien.

²²⁵ Véase Brav et al. (2008) para un análisis exhaustivo de cómo el activismo de los fondos de cobertura afecta el desempeño y la valoración de las empresas. compensación ejecutiva y seguridad laboral.

²²⁶ A partir de 2024, los principales actores de este mercado incluyen Nasdaq IR Intelligence (que incluye una "unidad de activismo" con "analistas de vigilancia"), "Visibilidad en tiempo real de las acciones de los activistas" de S&P Global y algunas empresas especializadas como Diligent Market Intelligence, FIS y Q4.

que una violación de la igualdad de derechos, ya que todos los participantes podrían tener acceso a las mismas divulgaciones públicas o datos externos. Es importante destacar que dicha información es universal (disponible para cualquiera con la tecnología necesaria) y desigualmente accesible debido a la experiencia y los recursos necesarios para la recopilación y el análisis de datos. Esta dinámica introduce una nueva forma de asimetría entre los externos, en lugar de entre los internos y los externos.

135

Un estudio de eventos revela que la precisión de los pronósticos de los analistas mejoró significativamente tras la disponibilidad de datos alternativos sobre el negocio de una empresa.²²⁷ Cabe destacar que esta mejora dependía de la afiliación del analista a una correduría equipada con sólidas capacidades de IA (definidas como empresas que emplean personal con formación relacionada con la IA o experiencia laboral relevante). Si bien esto subraya el potencial de los datos alternativos para cerrar la brecha de información entre empresas e inversores, también destaca el surgimiento de una nueva división: los clientes de las corredurías habilitadas con IA obtienen una clara ventaja sobre los demás, ya que la tecnología avanzada de IA es esencial para extraer, procesar y sintetizar información práctica de conjuntos de datos grandes y complejos.

En consecuencia, esta asimetría de información no puede remediarse únicamente con regulaciones como la Reg FD, que se centra en garantizar el acceso equitativo a la información relevante. Esta regulación aborda la divulgación selectiva de información relevante no pública por parte de empresas que cotizan en bolsa. Establece que, cuando un emisor comparte dicha información con destinatarios específicos, como profesionales del mercado de valores o tenedores de valores que puedan operar con base en ella, también debe hacerla pública. El objetivo de la Reg FD es garantizar una divulgación completa y equitativa, pero el desafío radica en abordar la creciente brecha en la capacidad de aprovechar esta información eficazmente, una brecha que se ha visto agravada por los avances en las tecnologías de inteligencia artificial.

Este efecto se ha manifestado repetidamente en escenarios donde la tecnología beneficia desproporcionadamente a ciertos participantes del mercado, como los operadores de alta frecuencia (HFT), a expensas de los operadores tradicionales. Durante la última década, las bolsas de valores han puesto a disposición del público grandes cantidades de datos de mercado, incluyendo información detallada de la cartera de órdenes, datos de operaciones y otras métricas. Si bien esta transparencia aparentemente nivela el campo de juego, en la práctica ha permitido a las empresas de HFT explotar su ventaja tecnológica, procesando y actuando sobre esta información más rápido que los operadores tradicionales a través de estrategias como la anticipación de órdenes y el arbitraje de latencia. El entorno resultante ha contribuido a mayores diferenciales entre oferta y demanda y precios menos estables.²²⁸ La integración de la IA ha cambiado el HFT de estar puramente centrado en la velocidad a una combinación de velocidad, inteligencia y adaptabilidad, ampliando aún más la brecha entre los operadores avanzados y tradicionales.

Inteligencia

²²⁷ Cao y otros (2024).

²²⁸ Véase evidencia en Lewis (2014) y Coughlan y Orlov (2023).

Este cambio altera fundamentalmente la dinámica de la asimetría de la información. Si bien los datos alternativos democratizan el acceso a ciertos conocimientos y una divulgación más amplia y estricta permite obtener más información interna de la empresa, su uso oportuno y eficaz se limita a quienes cuentan con los recursos y la experiencia necesarios, especialmente aquellos con una ventaja tecnológica en IA. Esto crea una asimetría de doble nivel: reduce la brecha entre los participantes internos y externos, pero introduce disparidades entre los externos, ya que solo los participantes tecnológicamente más avanzados pueden aprovechar al máximo estas fuentes de datos.

La ventaja competitiva resultante para las empresas y los inversores que se destacan en el aprovechamiento de datos alternativos y el procesamiento de información refuerza el papel cambiante de la tecnología como herramienta de democratización y como barrera en los mercados modernos.

Esta mejora depende, sin embargo, de la afiliación del analista a una correduría que haya desarrollado una capacidad adecuada de IA. Dado que los analistas actúan como intermediarios de información para inversores externos, este hallazgo corrobora la idea de que los datos alternativos acortan la brecha de información entre las empresas y sus inversores, pero solo con la ayuda de la tecnología necesaria para extraer y sintetizar big data.

4.3.5 Nueva asimetría de la información: implicaciones políticas

Brecha tecnológica: vieja y nueva

La asimetría de la información ha sido una característica fundamental de los mercados financieros desde su creación. La fijación de precios de los activos depende de una negociación informada, lo que supone inherentemente un acceso desigual a la información, y dicha asimetría siempre se ha visto impulsada por una brecha de recursos. Ante la falta de negociación basada en información privilegiada manifiesta, obtener información aún no incorporada al precio de las acciones requiere invariablemente recursos para la adquisición de información, como la investigación. Sin embargo, el rápido avance de la tecnología de IA está transformando esta dinámica de un cambio "evolutivo" a uno "revolucionario", lo que requiere un replanteamiento fundamental en lugar de una adaptación gradual. Los marcos regulatorios tradicionales, como el Reglamento FD, se diseñaron para promover la igualdad de acceso a la información relevante no pública procedente de las empresas, abordando principalmente la brecha entre información privilegiada y externa.

Sin embargo, estos marcos ahora enfrentan desafíos planteados por las complejas capas de asimetría introducidas por las herramientas impulsadas por IA y la explosión de fuentes de datos alternativos.

En general, la IA tiene el potencial de nivelar el terreno de juego entre inversores internos y externos, un punto de discordia de larga data en el funcionamiento de los mercados de valores. En este sentido, la tecnología de IA representa un avance en la reducción de las ventajas de los inversores internos, lo que podría aumentar la confianza en los mercados financieros y fomentar la adquisición de información que conduce a precios de valores más informativos. Sin embargo, al mismo tiempo, la IA introduce un entorno de información más fragmentado y desigual entre los propios inversores externos. Esta emergente "brecha de IA" puede aumentar la demanda de delegación de cartera o de productos de inversión pasiva, a medida que los inversores menos ingeniosos se percatan de la creciente disparidad en las capacidades analíticas ("poder diferencial"), a pesar de tener el mismo acceso a los datos brutos y a la información, ya que esta se genera cada vez más fuera de la empresa.

Redefiniendo la igualdad de acceso en un mercado impulsado por la IA

La creciente capacidad diferencial para procesar información pública, impulsada por la adopción de herramientas avanzadas de IA, permite a ciertos participantes del mercado extraer información con mayor rapidez y precisión que otros. Si bien esta disparidad es inevitable, ciertas medidas podrían ayudar a reducir la brecha o evitar que se amplíe. Una medida viable es la exigencia de información legible por máquina. La estandarización de todos los registros corporativos en formatos optimizados para el procesamiento algorítmico —basándose en la implementación del Lenguaje Extensible de Informes Empresariales (XBRL) en 2009 por parte de la SEC— reduciría significativamente las barreras de entrada para una amplia gama de inversores y analistas.²²⁹

137

Los organismos reguladores podrían establecer plataformas centralizadas, financiadas con fondos públicos, para el acceso y análisis de datos en tiempo real, proporcionando información accesible a todos los participantes del mercado y ayudando a mitigar las disparidades tecnológicas. La IA puede impulsar aún más este esfuerzo democratizador al optimizar XBRL mediante el etiquetado automatizado, la extracción de información de datos no estructurados y la integración de fuentes de datos alternativas, lo que permite un análisis financiero más completo y preciso. Además, la IA puede transformar XBRL en una herramienta dinámica y en tiempo real para la generación de información predictiva, la elaboración de informes personalizados y la detección de fraudes, haciendo que los datos financieros sean más prácticos y accesibles para todos.

Uso justo de datos alternativos

La proliferación de datos alternativos, desde imágenes satelitales hasta la percepción en redes sociales, ha introducido una nueva dimensión de asimetría de la información, permitiendo a los participantes del mercado con recursos y capacidades avanzadas de IA extraer información antes que otros. Simultáneamente, los directivos de las empresas obtienen fuentes adicionales para fundamentar su toma de decisiones o evaluar la percepción de las partes interesadas. Dado que estos datos a menudo pueden incluir información sustancial no pública, los reguladores podrían establecer estándares éticos para la extracción y agregación de datos alternativos, garantizando así que el abastecimiento responsable respete la privacidad del consumidor y la información comercial confidencial. También se podría instar a las empresas a revelar las fuentes de datos alternativos que sirven de base para su toma de decisiones.

Se espera que el mercado privado desempeñe un papel crucial en la democratización del acceso a datos alternativos. La competencia entre empresas de tecnología de datos, sumada a la escala del mercado potencial y la disminución del valor marginal de la información a medida que más inversores se informan, reduce naturalmente el precio que estos esperan pagar por la información extraída. Este proceso fomenta el desarrollo de repositorios de datos alternativos de amplio acceso, lo que ayuda a garantizar que estos recursos mejoren la eficiencia del mercado sin favorecer desproporcionadamente a los participantes tecnológicamente más avanzados.

²²⁹ XBRL es un formato que define o "etiqueta" elementos de datos individuales en la divulgación de estados financieros en un formato estandarizado. Con datos formateados de esta manera, los inversores y analistas pueden descargar datos de estados financieros de archivos públicos directamente a hojas de cálculo y otras herramientas de software, lo que permite un rápido análisis y comparación entre múltiples empresas, períodos de informes e industrias.

Abordando el comportamiento algorítmico. Los

algoritmos de negociación basados en IA han acelerado la velocidad y la complejidad de los mercados financieros y han creado nuevos riesgos, como la colusión algorítmica y las distorsiones de precios, que a menudo son involuntarias desde la perspectiva de la toma de decisiones humana. La colusión se produce cuando algoritmos independientes coordinan implícitamente el comportamiento, lo que conduce a resultados anticompetitivos como la manipulación de precios, mientras que ciertas estrategias exacerban la volatilidad o explotan las oportunidades de arbitraje, desestabilizando los mercados. Las respuestas regulatorias deben centrarse en garantizar que los beneficios de la negociación algorítmica, como la mejora de la liquidez y la reducción de los diferenciales entre oferta y demanda,²³⁰ no se vean socavados por ineficiencias sistémicas o prácticas desleales. Esto refleja el análisis del capítulo 3 de este informe.

Las herramientas de IA también pueden ayudar a los responsables políticos, en la vigilancia en tiempo real, a detectar patrones de negociación colusorios o desestabilizadores, como operaciones coordinadas, operaciones congestionadas o retiradas inusuales de liquidez. Exigir transparencia en los marcos algorítmicos, incluyendo la divulgación de los objetivos de optimización y las fuentes de datos, permitiría a los reguladores evaluar mejor los riesgos sin comprometer las preocupaciones sobre la propiedad intelectual. Además, la implementación de "reductores de velocidad" en ciertos contextos de negociación —similares a las medidas adoptadas por IEX²³¹— puede reducir estrategias perjudiciales como el arbitraje de latencia y mejorar el descubrimiento de precios al dar tiempo a los mercados para procesar la información fundamental. Estas intervenciones ayudarían a equilibrar las mejoras en la eficiencia de la negociación impulsada por IA con la necesidad de estabilidad y equidad del mercado.

Efecto de retroalimentación

La adaptación de las empresas a la divulgación de información para atender a los lectores automáticos ofrece un ejemplo ilustrativo del «efecto de retroalimentación» de la tecnología. Si bien los mercados financieros reflejan los fundamentos de la empresa, la percepción del mercado (que ahora se ve impulsada por la IA) también influye en los conjuntos de información y la toma de decisiones de los gerentes.^{²³²}

Este efecto de retroalimentación es inevitable porque las reglas codificadas que rigen el aprendizaje automático no son completamente opacas (es decir, son parcialmente observables y podrían ser sometidas a ingeniería inversa en diversos grados), y los agentes afectados por estas decisiones pueden verse tentados por incentivos a manipular las entradas de los algoritmos de aprendizaje automático para lograr resultados más favorables. Este efecto de retroalimentación puede dar lugar a resultados inesperados, como la manipulación y la colusión.^{²³³}

Por lo tanto, los algoritmos de aprendizaje automático se enfrentan al reto de ser «a prueba de manipulación», es decir, deben anticipar el comportamiento estratégico de los agentes informados sin observarlo directamente en las muestras de entrenamiento.^{²³⁴}

²³⁰ Hendershott et al. (2011) examinan el comercio algorítmico en la Bolsa de Valores de Nueva York (NYSE) durante 2001-2005.

y descubren que el trading algorítmico mejora la liquidez del mercado al reducir el diferencial entre oferta y demanda y aumentar la profundidad del libro de órdenes. Estas mejoras se atribuyen a la capacidad del trading algorítmico para procesar la información rápidamente y proporcionar liquidez continua, especialmente en acciones grandes y activas.

²³¹ Ejemplos de "reductores de velocidad" incluyen la introducción por parte de Investors Exchange (IEX) de un retraso de 350 microsegundos en todas las órdenes entrantes y salientes en 2016 para evitar el arbitraje de latencia, donde los operadores de alta frecuencia aprovechan su ventaja de velocidad para beneficiarse de las fluctuaciones de precios antes de que los participantes más lentos puedan reaccionar. La Bolsa TSX Alpha, parte del grupo de la Bolsa de Valores de Toronto, implementó un retraso de 1 a 2 milisegundos en ciertas órdenes en 2015. Esta medida tenía como objetivo disuadir las estrategias de HFT que explotan el flujo de órdenes, a la vez que permitía que el mercado mantuviera su eficiencia para la mayoría de los operadores. Véase Woodward (2018) para un análisis formal.

²³² Para un estudio completo sobre los efectos de retroalimentación, consulte Goldstein (2023).

²³³ Véanse los ejemplos dados en Calvano et al. (2020a).

²³⁴ Este desafío ha sido objeto de análisis teórico, como se ve en Björkegren et al. (2020) y Hennessy y Goodhart (2023).

Los reguladores también enfrentan el nuevo desafío de que las empresas podrían elaborar deliberadamente divulgaciones para engañar a los lectores de máquinas y al mismo tiempo cumplir técnicamente con los requisitos.

A diferencia de la tergiversación financiera tradicional, donde las empresas pueden omitir o tergiversar hechos relevantes, esta nueva forma de divulgación estratégica implica una sutil manipulación del lenguaje que explota la forma en que los modelos de IA y ML interpretan el sentimiento, el tono y el contexto. Los reguladores deberían explorar la colaboración con el mundo académico y expertos del sector para diseñar directrices de información financiera que equilibren la legibilidad de las máquinas con una transparencia veraz y favorable para los inversores. Es necesario distinguir entre la adaptación legítima a la IA (p. ej., mejorar la claridad para los lectores automáticos) y la optimización engañosa (p. ej., manipular la IA para evitar la clasificación negativa del sentimiento en el receptor).

139

4.4 La contratación financiera se encuentra con la IA

4.4.1 Eficiencia en la contratación principal-agente mejorada mediante IA

La Sección 4.2 se centró en la contratación entre un principal humano y un agente de IA, pero la IA también influye en la eficiencia de la contratación entre principal y agente entre humanos. Vives y Ye (2025a) proporcionan el primer modelo teórico que vincula los avances en IA con la eficiencia de la monitorización en la relación crediticia. La tecnología de IA reduce la fricción de la distancia, transforma la información blanda en datos accesibles y facilita el seguimiento en tiempo real. La eficiencia contractual se traduce en un mayor volumen de préstamos, una menor influencia de la distancia, una competencia más intensa y tasas de interés más bajas.

En el ámbito de las finanzas corporativas, los directores (como las empresas o los accionistas) delegan tareas a agentes (desde altos directivos hasta trabajadores de base) que son responsables de producir bienes y servicios, y de crear valor para los accionistas y las partes interesadas.

Sin embargo, los agentes invariablemente tienen incentivos contradictorios y realizan acciones ocultas basadas en su información privada. En este contexto, los contratos deben encontrar un equilibrio entre incentivar el esfuerzo, compartir el riesgo y abordar los desafíos en la medición del rendimiento, todo lo cual se ve influenciado por la adopción de la IA en los flujos de trabajo.

En primer lugar, la IA mejora la productividad, especialmente en escenarios donde complementa el trabajo humano, incentivando a los trabajadores a esforzarse más bajo ciertos esquemas de incentivos basados en el rendimiento. Al aumentar la IA la productividad marginal de los agentes, las empresas y los gerentes pueden esperar un mayor esfuerzo por parte de los empleados, lo que acerca la alineación del esfuerzo al óptimo. Por ejemplo, las herramientas basadas en IA pueden acelerar la síntesis de datos, optimizar la toma de decisiones, mejorar la previsión o optimizar la ejecución de tareas, induciendo un mayor trabajo bajo el mismo incentivo, ya que los agentes esperan beneficiarse más de mayores resultados medibles.²³⁵

²³⁵ Hay abundante evidencia sobre la productividad mejorada por IA en una amplia gama de profesiones dentro y fuera de finanzas, como el análisis de acciones (Cao et al., 2024), las fusiones y adquisiciones (Han, 2024), las operaciones en el piso de operaciones (Brogaard y Zareei, 2022), la creación de contenido de video (Jiang et al., 2025a) y el trabajo legal (Armour et al., 2020).

En segundo lugar, la IA ya mejora la monitorización del rendimiento y tiene el potencial de ser aún más eficaz a la hora de reducir el ruido en la medición del esfuerzo y los resultados de los agentes. La magnitud del teletrabajo tras la COVID-19 no habría sido posible sin tecnologías de monitorización remota, automatización de tareas y colaboración virtual.

140 Mediante análisis avanzado de datos y aprendizaje automático, la IA proporciona señales más precisas y oportunas sobre la contribución de un agente, lo que permite incentivos más efectivos sin comprometer la distribución de riesgos en los contratos. Esto reduce la incertidumbre condicional que enfrentan ambas partes, permitiendo a los principales ofrecer contratos que incentivan el esfuerzo y mitigan la exposición del agente a riesgos incontrolables. Una mejor supervisión fortalece la rendición de cuentas, garantizando que la compensación basada en el rendimiento refleje las contribuciones reales y no factores externos.

Jiang et al. (2025b) comparan la predicción anterior con la realidad de los trabajadores estadounidenses mediante el análisis de 20 años de datos de la Encuesta sobre el Uso del Tiempo en Estados Unidos (ATUS). Observan que quienes trabajan en ocupaciones con mayor exposición a la tecnología de IA tienden a extender su jornada laboral, reducir su tiempo libre (ambos indicadores de un mayor esfuerzo) y percibir salarios más altos.

Pruebas específicas confirman que estos resultados están vinculados a la complementariedad entre humanos y tecnología, el aumento de la productividad y la mejora de la supervisión que permite la IA. Sin embargo, el estudio también subraya que las mejoras impulsadas por la IA en la eficiencia de la contratación no necesariamente se traducen en mejoras significativas en el bienestar de los agentes, según se mide mediante la conciliación de la vida laboral y personal y las evaluaciones de satisfacción de los empleados. El grado de beneficio de los trabajadores depende en gran medida de su poder de negociación y de la dinámica competitiva de los mercados laborales y de productos. En entornos laborales altamente competitivos o en industrias con baja influencia de los trabajadores, las rentas derivadas de las mejoras en la productividad y la eficiencia de la contratación impulsadas por la IA suelen ser captadas por los directores o transferidas a los consumidores. Por lo tanto, si bien la IA mejora la eficiencia técnica de los contratos, no necesariamente mejora intrínsecamente el bienestar de los agentes.

4.4.2 Contratos inteligentes, información dinámica y descentralización

La tecnología de IA está llamada a transformar la contratación financiera, con herramientas como la redacción de contratos basada en IA y el análisis de riesgos que ofrecen mejoras tangibles. Dos avances clave en la reestructuración de los contratos son los contratos inteligentes y la contratación en tiempo real. Los contratos inteligentes, impulsados por IA e integrados con blockchain, automatizan la ejecución de los términos cuando se cumplen las condiciones predefinidas, reduciendo la supervisión manual y aumentando la transparencia. Estos contratos son autoejecutables y minimizan errores y disputas, lo que beneficia las transacciones financieras. Al mismo tiempo, la IA permite contratos en tiempo real que se ajustan a medida que cambian las condiciones, por ejemplo, en respuesta a fluctuaciones del mercado o actualizaciones regulatorias. Este dinamismo garantiza que los acuerdos se mantengan alineados con la información y la normativa vigentes.

Los contratos inteligentes son inherentemente descentralizados porque operan en un sistema de registro distribuido que elimina la necesidad de intermediarios centralizados. Esta descentralización garantiza que los términos y la ejecución del contrato sean validados y aplicados por una red de nodos independientes, en lugar de depender de una sola autoridad o institución.

Desde una perspectiva económica, esto reduce los costos de transacción asociados con la supervisión y el cumplimiento, ya que la cadena de bloques proporciona un registro inmutable y transparente de toda la actividad contractual. Además, la descentralización fomenta la confianza entre las partes, especialmente en transacciones con información asimétrica, al garantizar que ningún participante pueda manipular el contrato ni su ejecución. Esta característica es especialmente valiosa en los mercados financieros, donde prevalecen los problemas de agencia y el riesgo de contraparte.

El consenso descentralizado tiene el potencial de ampliar el espacio de contratación al reducir el alcance de las contingencias no contratables, un tema que ocupa el núcleo de la literatura sobre contratos incompletos.²³⁶

141

Además, la transparencia que brindan las cadenas de bloques permite verificar muchas acciones previamente ocultas, mitigando así los problemas tradicionales de riesgo moral. Por ejemplo, en el modelo propuesto por Cong et al. (2021), el esfuerzo que realizan los mineros de criptomonedas es observable mediante el seguimiento de la frecuencia con la que resuelven problemas matemáticos mucho más simples que los utilizados en la prueba de trabajo.^{²³⁷}

En conjunto, estos avances ofrecen una automatización, transparencia y adaptabilidad sin precedentes para satisfacer las necesidades dinámicas de la contratación financiera moderna, pero plantean nuevos desafíos a medida que el modelo descentralizado se acerca a un modelo de gobernanza de democracia directa.

4.4.3 Contratos inteligentes con IA: Implementación y compromiso

Los contratos inteligentes se encuentran con la IA

Los contratos inteligentes consisten en código informático que ejecuta automáticamente la totalidad o parte de un acuerdo y se almacenan en un sistema de cadena de bloques. Una definición informativa y completa es que los contratos inteligentes proporcionan «términos sujetos a consenso descentralizado, a prueba de manipulaciones y, por lo general, autoejecutables mediante ejecución automatizada».²³⁸ La tecnología subyacente aprovecha algoritmos criptográficos y mecanismos de consenso distribuido, lo que garantiza que las transacciones sean a prueba de manipulaciones y se ejecuten solo cuando se cumplan las condiciones predefinidas. Esta innovación tiene amplias aplicaciones en finanzas, gestión de la cadena de suministro, sector inmobiliario y otros sectores, ofreciendo eficiencia, reducción de costos y mayor confianza en la contratación y las transacciones.²³⁹

Los contratos inteligentes ofrecen numerosas ventajas, como velocidad, eficiencia, transparencia, precisión, confianza, seguridad y ahorro de costos, todas ellas relevantes para el gobierno corporativo. En primer lugar, al eliminar la necesidad de intermediarios como corredores y abogados para validar los contratos legales firmados, los contratos inteligentes reducen el riesgo de manipulación por parte de terceros y minimizan los costos de transacción. En segundo lugar, los contratos inteligentes están diseñados para garantizar que ambas partes cumplan con sus obligaciones, promoviendo la confianza y la rendición de cuentas entre las partes involucradas, incluso en ausencia de interacciones comerciales o sociales previas o futuras previstas. Al reducir

²³⁶ Hart (1995).

²³⁷ Al mismo tiempo, Cong et al. (2023) advierten sobre la posibilidad de poder concentrado en una estructura descentralizada.

²³⁸ Cong y He (2019).

²³⁹ Varios artículos recientes, en particular Levi y Lipton (2018), Makarov y Schoar (2022) y John et al. (2023), han proporcionado revisiones exhaustivas de la mecánica de los contratos inteligentes.

Ante la necesidad de una costosa verificación o ejecución, los contratos inteligentes pueden eliminar ciertas fricciones contractuales de forma automatizada y sin conflictos.²⁴⁰ En tercer lugar, los contratos inteligentes también pueden mejorar la transparencia y la precisión al proporcionar un registro a prueba de manipulaciones de todas las transacciones en la cadena de bloques, lo que puede ayudar a prevenir comportamientos fraudulentos o poco éticos. Finalmente, los contratos inteligentes pueden abordar un problema importante en la contratación clásica: la renegociación estratégica ex post. Al hacer cumplir las reglas y condiciones basadas en acuerdos previos, los contratos inteligentes mitigan los problemas de selección adversa y riesgo moral.

Los contratos inteligentes se concibieron antes y sin la ayuda directa de la IA, en el trabajo pionero de Nick Szabo,²⁴¹ informático y jurista. Se volvieron prácticamente viables con el auge de la tecnología blockchain, en particular a través de plataformas como Ethereum, lanzada en 2015, que proporcionó un entorno descentralizado y programable para su implementación. Estos primeros contratos inteligentes operaban según reglas y condiciones predefinidas codificadas en su programación, apoyándose en la naturaleza determinista de las redes blockchain para ejecutar acciones sin intermediarios.

Se basaban en reglas y eran estáticos, sin ninguna forma directa de inteligencia. De hecho, Szabo describió una máquina expendedora como un ejemplo primitivo de contrato inteligente: acepta monedas y dispensa un producto sin necesidad de intermediario, cumpliendo automáticamente los términos de un contrato simple. Esta analogía ilustra que estos contratos son esencialmente más «robóticos» que «inteligentes».²⁴²

La integración de la IA en los contratos inteligentes y la gestión general de contratos es un avance reciente que introduce capacidades como la adaptabilidad, la toma de decisiones basada en datos y el procesamiento del lenguaje natural que van más allá de su diseño original basado en reglas.²⁴³ Al incorporar la IA, los contratos inteligentes pueden procesar y responder a información dinámica, lo que mejora su funcionalidad en comparación con los contratos tradicionales. Por ejemplo, los oráculos impulsados por IA pueden proporcionar datos de mercado en tiempo real, como precios de materias primas o tipos de cambio, para activar automáticamente las cláusulas contractuales. En un contrato de cobertura vinculado a los precios del combustible, un contrato inteligente habilitado con IA podría ajustar las condiciones de pago en función de las fluctuaciones diarias de los precios sin necesidad de intervención manual. El capítulo 2 de este informe ofrece un análisis de la monitorización y el seguimiento de garantías impulsados por IA.

Esta evolución transforma los contratos inteligentes desde construcciones estáticas del tipo "si-entonces" en sistemas adaptativos, similares a los contratos contingentes al estado en economía, donde los resultados dependen de condiciones realizadas.

Más allá de los datos en tiempo real, la IA también mejora la eficiencia y la robustez de los contratos inteligentes mediante el análisis predictivo. Los algoritmos de aprendizaje automático, por ejemplo, pueden analizar tendencias históricas para optimizar los parámetros contractuales, como la fijación de precios de ejercicio en contratos de opciones o el ajuste de los acuerdos de reparto de riesgos en los contratos de seguros. Estos algoritmos pueden

²⁴⁰ Harvey (2016); Cong y He (2019).

²⁴¹ Szabo (1994).

²⁴² Véase un argumento similar formulado por Yermack (2017) en el contexto de la gobernanza de blockchain.

²⁴³ Véase, por ejemplo, "La IA generativa centra la atención en la gestión de contratos", *Financial Times*, 3 de julio de 2024; "La IA inteligente Contratos: explorando el futuro de la automatización basada en blockchain", *MI Ethereum*, 17 de mayo de 2024.

También detectan patrones indicativos de posible fraude o incumplimiento, lo que permite modificaciones preventivas de contratos o sanciones automáticas. Al integrar la IA, los contratos inteligentes abordan desafíos comunes en la teoría contractual, como la información asimétrica y el riesgo moral, ofreciendo soluciones que no solo están más automatizadas, sino que también se ajustan mejor a las complejidades económicas del mundo real.

143

Poder y limitaciones de los contratos inteligentes

Por las razones expuestas en la sección anterior, los contratos inteligentes son más adecuados para situaciones donde un compromiso sólido ex ante prevalece sobre una renegociación ex post y donde la discreción en la implementación no se valora o incluso puede ser perjudicial, dado su potencial para fomentar un comportamiento estratégico en escenarios cruciales. Esta comparación transversal no se ha examinado ni teórica ni empíricamente en la creciente literatura sobre contratos inteligentes. Por lo tanto, nuestros argumentos se basan principalmente en estudios previos dentro del marco de gobernanza tradicional. No obstante, nuestro enfoque en las propiedades inherentes de los contratos inteligentes nos permite proyectar tanto sus capacidades como sus limitaciones en el ámbito de la contratación.

En la práctica, a menudo es difícil predecir si la renegociación ex post será beneficiosa o perjudicial. Puede resultar ventajosa cuando proporciona información actualizada para llenar vacíos en la contratación incompleta,²⁴⁴ o cuando la redistribución del riesgo se vuelve óptima en términos de Pareto después de que un agente ha extendido el esfuerzo pero antes de que el resultado se haya realizado completamente.²⁴⁵ Por otro lado, la posibilidad de una renegociación ex post incentiva el riesgo moral, particularmente en forma de incumplimiento estratégico. Distinguir entre el incumplimiento desencadenado por el flujo de caja y el incumplimiento estratégico puede ser difícil, especialmente en una recesión o recesión económica.²⁴⁶ La teoría económica sugiere que incluso el código o la plataforma más sofisticados no pueden dar cuenta de todas las posibles contingencias.²⁴⁷ En otras palabras, muchos contratos financieros, como los acuerdos de préstamo, son inherentemente incompletos.²⁴⁸ Los contratos inteligentes estándar, que están "codificados" e impiden la renegociación, pueden no ser ideales para situaciones contractuales donde es difícil especificar contingencias o donde se desea compartir el riesgo ex post.

El equilibrio entre la activación obligatoria y discrecional de las condiciones contractuales presenta una dinámica intrigante. Como se analiza en la Sección 4.3.1, la toma de decisiones basada en algoritmos es transparente y, en algunos casos, puede ser objeto de ingeniería inversa, lo que podría incentivar comportamientos dirigidos a activar el algoritmo, a menudo con consecuencias imprevistas. Los contratos inteligentes, debido a su naturaleza mecánica, son inherentemente limitados para abordar contingencias que implican "efectos de retroalimentación". Un ejemplo relevante es el diseño de los bonos convertibles contingentes (CoCos) emitidos por los bancos. Los CoCos son instrumentos de deuda que se amortizan o se convierten en capital al desencadenarse una inviabilidad.

²⁴⁴ Hart y Moore (1988).

²⁴⁵ Fudenberg y Tirole (1991).

²⁴⁶ Véase Ganong y Noel (2023) para un ejemplo.

²⁴⁷ Aramonte y otros (2021).

²⁴⁸ Esta narrativa es un tema recurrente en los trabajos clásicos sobre la teoría de los contratos, incluidos Coase (1937), Grossman y Hart (1986), Hart y Moore (1988) y Aghion y Bolton (1992).

condición. La condición de activación puede definirse objetivamente, por ejemplo, a través de precios de mercado (sin renegociación que pueda asignarse a un contrato inteligente), o dejarse a la discreción de los reguladores (permitiendo una posible renegociación).²⁴⁹ La coexistencia de ambos tipos de activadores resalta las fortalezas y debilidades de cada enfoque como mecanismo de cumplimiento para la conversión de deuda en capital.

La discreción para activar la conversión suele conllevar el riesgo de fomentar el riesgo moral debido a la posibilidad de renegociación (incluso si es implícita). Consideremos el escenario de un banco que se acerca al umbral de inviabilidad que desencadenaría la conversión de CoCo. Si los reguladores conservan la discreción para activar la conversión, podrían dudar en actuar con prontitud, temiendo la posible desestabilización de los mercados o las consecuencias políticas de señalar eficazmente que un banco está en problemas. Esta vacilación puede fomentar el riesgo moral. Los bancos pueden apostar por la recuperación, adoptando estrategias más arriesgadas bajo el supuesto de que los reguladores, recelosos de las implicaciones más amplias de la activación, intervendrán para protegerlos.

Por el contrario, la activación obligatoria de los CoCos, si bien elimina la incertidumbre de la discreción regulatoria, introduce su propio conjunto de problemas, en particular el riesgo de una "espiral de la muerte".²⁵⁰ Por ejemplo, si la conversión de los CoCos se activa automáticamente con base en un umbral de precio de mercado, como a través de un contrato inteligente, la anticipación del incumplimiento puede hacer que los inversores se deshagan del capital vinculado al banco antes de la dilución. Esta presión de venta deprime aún más el valor de mercado del banco, acelerando el incumplimiento y activando la conversión prematuramente. Este bucle de retroalimentación que se retroalimenta puede erosionar rápidamente la confianza en el banco y desestabilizar el sistema financiero en general. Por lo tanto, los contratos inteligentes mecánicos en los mercados financieros pueden exacerbar estas dinámicas, dando lugar a resultados en los que el instrumento destinado a estabilizar al banco acelera, en cambio, su declive.

Los contratos inteligentes implican varias limitaciones adicionales, algunas de las cuales están directamente relacionadas con sus características técnicas. Por ejemplo, los contratos inteligentes dependen inherentemente de los programadores y son vulnerables a errores y errores lógicos en el código. Cualquier error podría resultar en riesgos significativos para todas las partes involucradas, lo que lleva a algunas empresas de blockchain a contratar auditores para evaluar la integridad de sus contratos inteligentes.²⁵¹ Existen varios elementos que involucran características explícitas o implícitas de gobernanza. En primer lugar, resulta difícil para los mecanismos de gobernanza descentralizada conciliar objetivos contrapuestos entre múltiples partes, lo que resulta en inestabilidad sistémica al enfrentar disputas de gobernanza dentro de las comunidades de blockchain, especialmente cuando se trata de decisiones críticas sobre actualizaciones de protocolos o cambios en las reglas contractuales. Esta limitación fue responsable del colapso final del sistema Terra-Luna en mayo de 2022.²⁵²

²⁴⁹ Para una descripción general completa del mercado de CoCo, así como modelos teóricos y evidencia empírica, véase Avdjiev et al. y col. (2020).

²⁵⁰ Véase el modelo teórico de Sundaresan y Wang (2015) sobre la «espiral de muerte» del CoCo.

²⁵¹ Bourveau y otros (2023).

²⁵² Por ejemplo, en un incidente relacionado con la plataforma DeFi YAM Finance, los desarrolladores del proyecto introdujeron un error en el contrato inteligente, lo que provocó el colapso de todo el proyecto y generó pérdidas significativas para los inversores. Lehar y Parlour (2023) también describen un ataque de préstamo flash que aprovechó un error de codificación de una plataforma descentralizada.

²⁵³ Liu y otros (2023).

En segundo lugar, los contratos inteligentes operan principalmente en entornos digitales en línea, pero a menudo interactúan con eventos y datos del mundo real fuera de línea. Los contratos inteligentes no pueden recuperar datos de fuentes externas más allá de la red blockchain, lo cual es necesario con varias aplicaciones del mundo real. Por ejemplo, los datos meteorológicos externos pueden ser requeridos por un contrato inteligente que basa los pagos de seguros en las condiciones climáticas. Se basan en fuentes de datos o servicios confiables ("oráculos") para proporcionar información sobre eventos o condiciones del mundo real.²⁵⁴ Esto expone los contratos inteligentes a problemas de gobernanza mundanos en el mundo fuera de línea. Los oráculos, por ejemplo, pueden manipularse a través del arbitraje (que utiliza préstamos flash), especialmente a través de protocolos DeFi.²⁵⁵ Además, en las transacciones que involucran activos físicos, los contratos inteligentes deben integrarse con las estructuras legales convencionales.

En tercer lugar, si bien los contratos inteligentes en sí mismos no fomentan inherentemente comportamientos estratégicos como la colusión, ciertas condiciones o factores dentro de un sistema o ecosistema de contratos inteligentes pueden crear oportunidades de colusión entre los participantes. Algunos comportamientos colusorios no difieren en naturaleza del comportamiento estratégico que se extiende del mundo real al mundo en línea con formas ligeramente diferentes. Por ejemplo, la concentración de tokens puede incitar a un pequeño grupo de participantes a coludir para controlar los procesos de gobernanza coordinando sus votos para influir en los resultados. Los operadores de oráculos que coluden podrían proporcionar datos falsos o manipulados para activar resultados contractuales que les beneficien económicamente. Más importante aún, algunos tipos de comportamiento colusorio se han visto fomentados precisamente por la transparencia que proporciona el consenso descentralizado, que se habría visto disuadida por la asimetría de la información o la falta de compromiso. Cong y He (2019) demuestran que los contratos inteligentes pueden fomentar la colusión entre las partes interesadas, ya que la transparencia y el compromiso de la blockchain ayudan a mantener el equilibrio colusorio. En las aplicaciones DeFi, los contratos inteligentes podrían explotarse coludiendo con los participantes para crear cárteles que manipulen los precios de los tokens o ejecuten oportunidades de arbitraje, lo que podría perjudicar a otros.

usuarios.

Hasta el momento, solo un estudio ha aportado evidencia empírica de las ventajas y desventajas de la contratación incompleta.²⁵⁶ Mediante la adopción escalonada de leyes estatales de EE. UU. que abren nuevas oportunidades para el uso de la tecnología blockchain dentro del estado, los autores concluyen que las empresas que la han utilizado experimentan una mejora significativa en su rendimiento. De mayor relevancia para la tecnología blockchain, los autores muestran que dichas empresas se vuelven menos dependientes de la integración vertical, establecen alianzas estratégicas con mayor frecuencia y captan nuevos clientes sin importar la proximidad geográfica.

²⁵⁴ Los oráculos pueden ser interfaces de programación de aplicaciones (API) o páginas web. Consulte Beaver Finance (2022) para conocer los distintos tipos de oráculos.

²⁵⁵ Según Chainalysis (2023), los inversores de DeFi perdieron alrededor de 865 millones de dólares en docenas de ataques de oráculos entre 2020 y 2022. Consulte Harvey et al. (2021) para obtener ejemplos adicionales de ataques de oráculo.

²⁵⁶ Chen y otros (2023).

4.4.4 Renegociar con IA

El arma de doble filo de la renegociación de contratos La IA

ha transformado la gestión de contratos al automatizar muchos aspectos de la contratación, incluyendo la redacción, la ejecución y la supervisión. Los contratos impulsados por IA permiten una implementación continua y fluida, ajustándose dinámicamente a las condiciones cambiantes basadas en datos en tiempo real y algoritmos predefinidos. Estas características reducen los costos de transacción, minimizan las disputas y garantizan una ejecución más fluida en comparación con los acuerdos estáticos tradicionales. Sin embargo, a pesar de estos avances, los contratos suelen ser incompletos por naturaleza, ya que no pueden anticipar por completo todas las contingencias futuras o los cambios de prioridades. Como resultado, hay momentos en que la renegociación se vuelve esencial, ya sea para tener en cuenta circunstancias imprevistas, adaptarse a nueva información o reequilibrar los intereses de las partes contratantes. En estas situaciones, la rigidez de la IA para seguir reglas preprogramadas puede plantear desafíos, ya que a menudo se necesita la intervención humana para revisar los términos, abordar ambigüedades y negociar actualizaciones que se alineen con las realidades actuales.

La contratación de hipotecas ejemplifica tanto las ventajas como las desventajas de las capacidades de la IA. Esta puede monitorizar los patrones de pago, detectar indicios tempranos de dificultades y disuadir el incumplimiento estratégico de los prestatarios mediante el análisis de su comportamiento y patrones financieros para identificar a aquellos capaces de pagar, pero que optan por no hacerlo. Los prestatarios pueden optar por el incumplimiento estratégico cuando el coste percibido de continuar con los pagos supera los beneficios, como en casos de patrimonio neto negativo, donde el valor de la propiedad cae significativamente por debajo del saldo de la hipoteca, o cuando existe la posibilidad de una modificación del contrato a su favor cuando una ejecución hipotecaria resulta costosa para el prestamista. Mediante la monitorización en tiempo real del historial de pagos, los hábitos de gasto y las condiciones económicas externas, la IA puede señalar anomalías que indiquen un posible incumplimiento estratégico. Una vez identificadas, la IA permite a los prestamistas implementar intervenciones específicas, como recordatorios de consecuencias legales o sanciones personalizadas que aumentan el coste del incumplimiento. Este enfoque proactivo desincentiva el comportamiento estratégico al garantizar que las consecuencias financieras o reputacionales del incumplimiento superen los beneficios percibidos.

Por otro lado, existen situaciones en las que las modificaciones hipotecarias son deseables o incluso necesarias para prevenir impagos generalizados y contagiosos causados por condiciones macroeconómicas adversas. Por ejemplo, durante recesiones económicas o desplomes del mercado inmobiliario, una caída drástica del valor de las propiedades puede dejar a muchos prestatarios con patrimonio neto negativo, donde incluso quienes pueden afrontar sus pagos pueden considerar la posibilidad de incumplir, mientras que quienes enfrentan dificultades financieras reales se enfrentan a una mayor presión financiera. Si los impagos se generalizan bajo una estricta aplicación de los contratos, pueden desencadenar una espiral descendente, deprimiendo aún más los precios de la vivienda, erosionando los balances de las entidades crediticias, arruinando barrios y desestabilizando la economía en general. Las modificaciones hipotecarias, como la ampliación de los plazos de los préstamos, la reducción de los tipos de interés o el ajuste del capital principal, pueden proporcionar alivio a los prestatarios, incentivando la continuidad de los pagos y rompiendo el ciclo de contagio.

Es natural que la IA muestre rigidez al ejecutar reglas preprogramadas y términos contractuales predefinidos, lo que puede limitar su capacidad de adaptación a shocks macroeconómicos inesperados o circunstancias particulares de los prestatarios. Esta rigidez garantiza la consistencia y la eficiencia, pero puede exacerbar los riesgos sistémicos cuando se requieren modificaciones generalizadas, ya que la IA carece de la discreción para evaluar las condiciones económicas más amplias o las implicaciones sociales. Sin embargo, la IA tiene potencial de flexibilidad cuando se programa para identificar patrones indicativos de estrés económico y recomendar intervenciones específicas. Por ejemplo, la IA puede analizar datos sobre dificultades de los prestatarios, tendencias del mercado inmobiliario e indicadores macroeconómicos para sugerir modificaciones personalizadas, como reducciones de capital o extensiones de plazo, que los responsables de la toma de decisiones pueden evaluar e implementar en un contexto económico y social más amplio. contexto.

147

Adaptación de la IA en la renegociación de contratos. El proyecto AIA Co, patrocinado por la Unión Europea, es una iniciativa pionera que aborda el impacto de la COVID-19 en los contratos de arrendamiento comercial y demuestra cómo la IA puede facilitar una renegociación eficiente y equitativa ante crisis económicas imprevistas. Durante la pandemia, muchos arrendatarios experimentaron graves dificultades financieras debido a los cierres obligatorios, lo que obligó a ajustar las condiciones de los arrendamientos para evitar impagos generalizados. El proyecto utilizó marcos predictivos basados en IA para ayudar a las autoridades judiciales y a las partes contratantes a renegociar las condiciones, como los aplazamientos o reducciones de alquiler, adaptadas a las condiciones económicas dinámicas. Esta aplicación se alinea con las teorías económicas de los contratos incompletos, que enfatizan que los contratos, por naturaleza, no pueden contemplar todas las contingencias futuras y, por lo tanto, deben equilibrar los incentivos para la inversión y las ineficiencias de la negociación ex post.²⁵⁷

Un estudio que analiza el proyecto AIA destaca la capacidad de la IA para analizar datos granulares y predecir las implicaciones de las modificaciones contractuales, lo que introduce un enfoque estructurado e impulsado por datos para la renegociación, llenando las lagunas que dejan los diseños contractuales rígidos.²⁵⁸ Al abordar estas lagunas, la IA mejora la adaptabilidad contractual al tiempo que mantiene el equilibrio entre la eficiencia y la equidad, incluso frente a shocks sistémicos.

Integración

4.4.5 Compromiso y flexibilidad con la IA: implicaciones políticas

La integración de la IA en la contratación financiera no elimina la disyuntiva fundamental entre el compromiso ex ante y la flexibilidad ex post. Si bien la IA mejora la eficiencia de la contratación mediante una mejor supervisión, el análisis predictivo y la ejecución automatizada, su utilidad se maximiza al combinarse con la supervisión humana y la adaptabilidad dinámica.

²⁵⁷ Hart y Moore (1988).

²⁵⁸ Parton y otros (2022).

Desencadenantes de renegociación predefinidos

Los sistemas de IA no solo deberían automatizar la ejecución de contratos, sino también incorporar desencadenantes predefinidos para la renegociación. Estos desencadenantes podrían estar vinculados a variables macroeconómicas o específicas del mercado mensurables, como los índices de precios de la vivienda, las fluctuaciones en los tipos de interés o las tendencias de empleo sectoriales. Por ejemplo, en los contratos hipotecarios, la IA podría monitorizar continuamente la caída del valor de las propiedades o las recesiones económicas regionales para advertir la probabilidad de impagos masivos. Al automatizar este aviso, la IA puede facilitar la renegociación proactiva para prevenir riesgos sistémicos, como impagos en cascada o crisis de liquidez. Este enfoque se alinea con las teorías de la contratación incompleta, que abogan por el diseño de mecanismos para abordar contingencias que, en su mayoría, no se deben al riesgo moral, que son difíciles de especificar ex ante, pero que son cruciales para la eficiencia a largo plazo.

Contratación híbrida entre IA y humanos

Si bien la IA puede analizar grandes cantidades de datos y ofrecer recomendaciones precisas para ajustes contractuales, aún carece del criterio contextual necesario para evaluar las implicaciones más amplias de estos ajustes. Los responsables de la toma de decisiones humanas son cruciales para evaluar las consecuencias económicas, legales y sociales de las modificaciones contractuales que la IA podría pasar por alto. Por ejemplo, durante una crisis financiera, la IA podría sugerir una renegociación hipotecaria generalizada basándose únicamente en la reducción del riesgo de impago, pero la supervisión humana puede sopesar las compensaciones entre la solvencia del prestamista y el alivio del prestatario. Los responsables políticos deberían fomentar sistemas híbridos donde la información generada por la IA guíe las decisiones, mientras que los agentes humanos conservan la discreción para considerar impactos sociales más amplios, como la estabilidad del vecindario o la confianza del consumidor.

Transparencia en la contratación de IA

La transparencia en los sistemas de IA es fundamental para garantizar la confianza y la rendición de cuentas en la contratación financiera. Los contratistas deben proporcionar documentación clara y accesible de los marcos de toma de decisiones de los algoritmos de IA, en particular en lo que respecta a los factores desencadenantes de la renegociación y la justificación de los ajustes contractuales sugeridos. Por ejemplo, si un sistema de IA detecta un préstamo corporativo para su renegociación, su decisión debe ir acompañada de una explicación de los patrones de datos o las condiciones económicas que la desencadenan.

Este nivel de transparencia mitiga las disputas y fomenta la confianza entre las partes contratantes. Además, garantiza que los sistemas de IA sigan siendo auditables, lo que permite a los reguladores evaluar el cumplimiento y emitir fallos en las disputas.

Flexibilidad compatible con incentivos

Los sistemas de IA, al igual que sus homólogos humanos, deben priorizar la compatibilidad dinámica de incentivos, garantizando que los contratos no fomenten comportamientos estratégicos de ninguna de las partes, al tiempo que se adaptan a las circunstancias cambiantes. Por ejemplo, en el ámbito hipotecario, la IA podría ayudar a identificar a los prestatarios en riesgo de impago y recomendar condiciones de pago modificadas que mantengan los incentivos para el reembolso. Simultáneamente, los contratos deben protegerse contra comportamientos oportunistas, como el incumplimiento estratégico o la tergiversación de la información financiera.

La dificultad, al garantizar que las modificaciones sigan estando sujetas a criterios verificables. Este equilibrio entre flexibilidad y compromiso refuerza la credibilidad de los contratos, adaptándose a la realidad económica, y materializa los principios de la teoría contractual que priorizan la alineación de incentivos entre todas las partes.

4.5 CONCLUSIÓN

La integración de las finanzas y la tecnología representa una transformación dinámica y multifacética del gobierno corporativo y los sistemas de mercado, que resuelve algunos problemas y crea otros. Este capítulo examina cómo la inteligencia artificial, el aprendizaje automático y el big data transforman los problemas fundamentales asociados con las finanzas y el gobierno corporativo, incluyendo los problemas de agencia, la asimetría de la información y la contratación incompleta. La IA introduce un nuevo paradigma de agencia donde los sistemas actúan como oráculos, agentes o soberanos, lo que complica los procesos de rendición de cuentas y toma de decisiones. Si bien la IA elimina los riesgos morales tradicionales, como la elusión, crea riesgos al optimizar objetivos programados que pueden entrar en conflicto con objetivos de bienestar más amplios o estrategias a largo plazo. La proliferación de datos alternativos y análisis basados en IA exacerba la asimetría de la información pública, aumentando las desigualdades en el procesamiento de la información y el poder de mercado a pesar del acceso universal a los datos. Mientras tanto, los contratos inteligentes basados en blockchain reducen los costos de cumplimiento, pero desafían la flexibilidad en la renegociación, lo que resalta la tensión entre eficiencia y adaptabilidad.

A medida que la tecnología se integra y transforma los sistemas financieros, nivela algunas condiciones de competencia, pero genera nuevas desigualdades, lo que exige una reevaluación de los marcos de gobernanza. Este capítulo subraya la necesidad de estructuras económicas y de gobernanza que aprovechen el poder transformador de la tecnología, garantizando al mismo tiempo la equidad, la rendición de cuentas y la eficiencia. Los académicos deben ahora abordar no solo la investigación financiera con tecnología sino también 'financiar la investigación sobre tecnología', navegando con eficacia por esta frontera en rápida evolución.

Discusiones

5.1 DISCUSIÓN DEL CAPÍTULO 2, "INTELIGENCIA ARTIFICIAL Y EL SECTOR FINANCIERO: TRANSFORMACIONES, RETOS Y RESPUESTAS REGULATORIAS", POR DIANA BONFIM²⁵⁹

150

INTELIGENCIA

De repente, la IA parece estar en todas partes. La adopción generalizada e inmediata de ChatGPT en noviembre de 2023 hizo que el mundo comprendiera que la IA ya no es un concepto lejano de ciencia ficción, sino algo disponible para todos, en todo momento, al alcance de la mano.

Sin duda, el sector financiero no se ha sorprendido tanto como la mayoría de nosotros ante el poder y la omnipresencia de la IA. Como muestra el capítulo 2 de este informe, la IA se ha utilizado en el sector financiero desde hace mucho tiempo. Si bien los populares modelos de lenguaje grande (LLM) son una incorporación reciente, el sector financiero lleva mucho tiempo aprovechando el potencial de los datos que posee mediante el uso de herramientas de IA, como técnicas avanzadas de aprendizaje automático.

El capítulo 2 analiza las oportunidades, los desafíos y las respuestas regulatorias. Las oportunidades son enormes y quizás aún difíciles de comprender por completo. En resumen, la IA permite a los bancos realizar avances significativos en sus dos áreas principales de especialización: selección y monitoreo.²⁶⁰ La función de intermediación financiera de los bancos se basa en su capacidad para seleccionar a los prestatarios. El préstamo directo es ineficiente si depende de la capacidad de los ahorradores para canalizar eficientemente sus fondos hacia las oportunidades de préstamo más solventes y rentables. Los bancos han crecido gracias a su experiencia en la identificación de estas oportunidades. Si bien el conocimiento humano acumulado por los asesores de crédito sigue siendo importante hoy en día, las máquinas son indiscutiblemente más eficientes en el procesamiento de la enorme cantidad de datos disponibles. Esto permite a los bancos (y a las entidades no bancarias) optimizar la relación entre riesgo y rentabilidad de forma más eficiente, identificando a los prestatarios que pueden contribuir a maximizar las ganancias, sujetos a las preferencias de riesgo y los límites regulatorios. Cuando se dispone de datos, la IA puede realizar una selección mejor que los humanos,²⁶¹ contribuyendo así a reducir la exposición al riesgo crediticio en el sistema financiero.

El poder de la IA también es importante para la monitorización. Si bien el cribado mitiga el problema de la selección adversa en los préstamos, la monitorización mitiga el riesgo moral al que están expuestos los prestamistas. Los bancos deben mantenerse permanentemente alertas ante posibles deterioros del riesgo crediticio en su cartera de prestatarios. Históricamente, una estrecha relación entre prestamistas y prestatarios ha sido importante para que los bancos puedan identificar riesgos de forma temprana.²⁶² Las garantías también desempeñan un papel clave en este proceso, permitiendo una mejor alineación de los incentivos entre

²⁵⁹ Estas son las opiniones del autor y no las del Banco de Portugal ni del Eurosistema.

²⁶⁰ Carletti (2004); Mester et al. (2007); Stiglitz y Weiss (1988).

²⁶¹ Gambacorta y otros. (2024a).

²⁶² Berger y Udell (1995); Dass y Massa (2011); Degryse y Ongena (2005); Kysucky y Norden (2016); Rajan (1992).

prestarios y prestamistas.²⁶³ Dicho esto, es necesario supervisar la propia garantía, ya que las pérdidas esperadas dependen fundamentalmente de la capacidad de recuperar su valor en caso de incumplimiento. Por lo tanto, tanto para exposiciones con garantía como sin ella, la IA puede ayudar a los prestamistas a procesar toda la información disponible para supervisar adecuadamente los riesgos a los que están expuestos.

El capítulo muestra que los beneficios de la IA en las finanzas no son exclusivos del sector privado. De hecho, los bancos centrales han estado a la vanguardia del uso de la IA para cumplir con sus mandatos. El capítulo se refiere a muchas aplicaciones que ayudan a los bancos centrales a salvaguardar la estabilidad de precios y la estabilidad del sistema financiero. Los estadísticos han estado utilizando herramientas de IA para recopilar, procesar y compilar información estadística. Los economistas que participan en el análisis macroeconómico y financiero para fines de política monetaria y macroprudencial utilizan técnicas de aprendizaje automático y LLM para identificar desarrollos actuales y futuros en la economía y el sistema financiero, contribuyendo así a una formulación de políticas mejor informada. Los supervisores también pueden procesar grandes cantidades de datos para identificar riesgos y vulnerabilidades en las instituciones financieras. Finalmente, la supervisión de los sistemas de pago, que se basa en cantidades insuperables de datos, también se beneficia del uso de herramientas de IA para detectar anomalías y disrupciones.

En general, los beneficios de la IA en el sistema financiero ya son visibles y significativos, pero es probable que estos sean los primeros pasos de más cosas que vendrán.

Por supuesto, las nuevas oportunidades a menudo implican nuevos riesgos. Cuanto mayor sea el avance en términos de innovación, más graves y generalizados serán los riesgos. El capítulo 2 identifica varios desafíos importantes: sesgo y discriminación, riesgo legal, ciberseguridad, concentración del mercado, el papel dominante de las grandes tecnológicas y riesgos para la estabilidad financiera. Como se analiza en el capítulo, estos son problemas antiguos, pero la IA plantea nuevos desafíos.

Con el tiempo, los responsables políticos se han esforzado por mitigar los prejuicios y la discriminación, adoptando medidas de protección al consumidor y prácticas crediticias justas. Podría argumentarse que la IA podría ser ciega a los prejuicios y la discriminación humanos. Sin embargo, así como los humanos a veces no son conscientes de sus actitudes y prejuicios, la IA también puede ser un poco humana en este aspecto. Esto no se debe a la inteligencia en sí, sino a los algoritmos y los datos utilizados para alimentar los modelos.²⁶⁴

El capítulo también aborda una preocupación importante relacionada con el riesgo legal. El hecho de que los modelos de IA sean generalmente una "caja negra", agravado por problemas de alucinaciones, puede conllevar un mayor riesgo de litigio. Respaldo y defender decisiones pasadas puede no ser tan fácil como si existiera un rastro humano de toma de decisiones.

La preocupación por la ciberseguridad también es inevitable. El propio cibercrimen depende cada vez más de la IA, y los sistemas de IA también pueden ser más vulnerables a los ataques. Sin embargo, la IA también ofrece importantes oportunidades de ciberresiliencia, que el sector financiero debería aprovechar.

²⁶³ Berger y Udell (1990); Stiglitz y Weiss (1981).

²⁶⁴ Fuster y otros (2022).

El capítulo incluye un análisis detallado y profundo de la cadena de suministro de IA.

Según Gambacorta y Shreeti (2025), la cadena de suministro de IA se estructura en torno a cinco componentes: hardware, computación en la nube, datos de entrenamiento, modelos de base y aplicaciones de IA. Todos estos requieren inversiones masivas y escalabilidad. A menudo, en algunas partes de esta cadena de suministro existe una dimensión de "el ganador se lo lleva todo", debido a la omnipresencia de las economías de escala, alcance y red. Esto ha provocado una concentración extrema del mercado en algunos segmentos de la cadena de suministro de IA, lo que inevitablemente genera riesgos.

El auge de las grandes tecnológicas es indisoluble de esto. Estas pueden aprovechar el ciclo creado por los estrechos vínculos entre los datos, los recursos de computación en la nube y los modelos de IA. Esto genera preocupación por un posible abuso de poder de mercado y la extracción de rentas de los consumidores.

El capítulo también analiza los riesgos para la estabilidad financiera. Los modelos de IA se basan en conjuntos de datos similares y las instituciones financieras utilizan modelos similares. Esto puede aumentar la volatilidad en los mercados financieros y el riesgo sistémico en el sistema en general. Por otra parte, existe incertidumbre sobre los efectos de la IA en la economía. Casi con toda seguridad, habrá ganadores y perdedores, como en cualquier revolución tecnológica. Si bien la exposición a los ganadores tendrá efectos secundarios positivos en el sistema financiero, ocurrirá lo contrario con quienes estén expuestos a los perdedores. Los esfuerzos para identificar quiénes podrían ser estos serán cruciales para mitigar futuras pérdidas.

El capítulo finaliza analizando cómo regular la IA. Existen compensaciones entre los vértices de un triángulo complejo: estabilidad, eficiencia y protección del consumidor. El capítulo establece algunos principios para regular la IA considerando estas compensaciones. Estos incluyen principios comunes como el bienestar social, la transparencia, la rendición de cuentas, la equidad, la protección de la privacidad, la seguridad, la supervisión humana y la robustez. Existen tres modelos a nivel mundial para abordar esto: un enfoque impulsado por el mercado en Estados Unidos, un enfoque impulsado por el Estado en China y un enfoque de protección social en Europa.

Sin embargo, como se destaca en el capítulo, la IA no se puede regular dentro de las fronteras y la cooperación internacional es esencial para garantizar un equilibrio adecuado entre los beneficios y los riesgos de la IA en las finanzas.

El capítulo es increíblemente rico y exhaustivo. Sin embargo, dadas las incógnitas sobre las implicaciones de la IA para el sistema financiero, surgen preguntas adicionales. ¿Cómo equilibrar las oportunidades y los riesgos en la selección? ¿Qué otros riesgos nuevos podrían surgir?

¿Cómo deberíamos considerar la regulación de los diferentes tipos de riesgos a los que están expuestos los bancos? ¿Cuáles son las implicaciones de un panorama geopolítico cambiante?

¿Cómo equilibrar las oportunidades y los riesgos en el cribado?

El capítulo presenta evidencia sólida de que los modelos de IA ofrecen una mayor precisión en la evaluación del riesgo crediticio, con base en la literatura existente.²⁶⁵ Sin embargo, una mayor precisión solo es posible cuando existen datos para entrenar y alimentar los modelos. Por ejemplo, las decisiones de aprobación y fijación de precios de los préstamos al consumo suelen basarse en datos estandarizados. Tradicionalmente, los solicitantes

²⁶⁵ Véase, por ejemplo, Gambacorta et al. (2024a).

Proporcionan información sobre su situación financiera y profesional, la cual se procesa mediante un modelo de calificación crediticia. La IA puede ampliar esta capacidad de diversas maneras, utilizando modelos de riesgo crediticio más potentes o explorando un conjunto más amplio de datos. Por ejemplo, se pueden aprovechar los comportamientos en línea para crear perfiles de riesgo más precisos que los basados únicamente en información autodeclarada.²⁶⁶ La financiación de hipotecas también está bastante estandarizada y basada en modelos. Para empresas grandes y consolidadas, con una gran cantidad de datos disponibles, la IA sin duda puede generar mejoras en la aprobación y la fijación de precios de préstamos.

Pero, ¿se aplica lo mismo a los segmentos del mercado crediticio donde la información asimétrica es más aguda? El debate sobre el rol de los préstamos basados en relaciones versus préstamos basados en transacciones no es nuevo,²⁶⁷ pero la IA lo lleva a un nivel diferente. Dadas las ganancias potencialmente grandes que ofrece la IA en préstamos que pueden basarse en información estandarizada, ¿cuán dispuestos estarán los bancos a financiar a las pequeñas y medianas empresas (PYME)? ¿Cuán costoso será esto? La decisión de financiar a empresas más pequeñas, que son mucho más opacas informativamente, generalmente requiere la recopilación de información blanda a través de una relación cercana entre el banco y la empresa. Esta interacción humana puede volverse más costosa en términos relativos, lo que dificulta aún más el acceso de las PYME a la financiación. Esto puede tener efectos perjudiciales en el empleo y la inversión, perjudicando el crecimiento económico.²⁶⁸ Las empresas emergentes pueden ser aún más vulnerables a esto. El conocimiento adquirido por los bancos al otorgar préstamos a empresas de reciente creación puede ser fundamental para determinar su crecimiento y éxito.²⁶⁹ Si a los bancos les resulta aún más costoso asumir estos riesgos (y a las empresas acceder a la financiación), corremos el riesgo de que la IA contribuya a una economía menos innovadora y dinámica. Dicho esto, existen resultados alentadores sobre la capacidad de la IA para mejorar también la evaluación de las empresas emergentes.²⁷⁰ El uso de datos no tradicionales e información sobre pagos también puede ser útil para empresas con mayor opacidad informativa.

Una preocupación relacionada es que la naturaleza basada en datos de las decisiones de selección de la IA puede reducir su capacidad para tomar las decisiones correctas después de interrupciones importantes o cambios estructurales. Por ejemplo, la pandemia de COVID-19 inutilizó la mayoría de los modelos de riesgo crediticio para la toma de decisiones durante ese período. Las empresas se vieron expuestas a un shock repentino de liquidez y su solvencia no pudo evaluarse únicamente con base en su desempeño financiero pasado. La pregunta clave era identificar qué empresas serían viables en el futuro si se les proporcionara liquidez para soportar confinamientos temporales e interrupciones en las cadenas de suministro. En un mundo en constante cambio, la información pasada no es necesariamente la mejor base para las decisiones, incluso si la no linealidad incorporada en los algoritmos de aprendizaje automático puede ofrecer flexibilidad.²⁷¹ En recesiones y períodos de crisis, el conocimiento humano que constituye la base del préstamo relacional ha demostrado ser crucial para mitigar el impacto de las crisis y ayudar a la recuperación económica.²⁷²

²⁶⁶ Berg y otros (2025).

²⁶⁷ Rajan (1992).

²⁶⁸ Bonfim y otros (2023).

²⁶⁹ Bonfim y otros (2025).

²⁷⁰ Lyonnet y Stern (2024).

²⁷¹ Gambacorta y otros. (2024a).

²⁷² Bolton y otros (2006).

Un punto interesante es que la IA puede cambiar la tendencia de aumentar la dependencia de las garantías para acceder a la financiación.²⁷³ Esto significa que las empresas e industrias para las que las garantías son escasas (intangibles) pueden superar las dificultades en el acceso al crédito. Si bien estas son buenas noticias, también hay compensaciones. En lugar de depender de las garantías, los prestamistas se basarán más en los datos. Esto puede ayudar a las empresas e industrias con un desempeño pasado positivo pero sin activos que puedan garantizarse a mejorar su acceso al crédito. Pero la IA tenderá a centrarse en los ganadores del pasado. Las industrias que tuvieron más éxito en el pasado tienen más probabilidades de tener mejores calificaciones crediticias en los modelos basados en datos. ¿Conducirá esto a una economía menos propensa a la innovación, donde las nuevas empresas tendrán aún más dificultades para acceder a la financiación?

¿Se volverá la economía menos flexible y capaz de adaptarse a los shocks, debido a la dependencia de algoritmos para la toma de decisiones?

¿Qué otros riesgos nuevos podrían surgir?

El capítulo analiza de forma excelente cómo los riesgos tradicionales pueden adoptar nuevas formas debido al papel de la IA en las finanzas. Sin embargo, inevitablemente surgirán nuevos problemas. Permítanme destacar dos.

En primer lugar, como se muestra en la Figura 9 del Capítulo 2, los bancos se basan en la confianza. Esta es la base del negocio bancario. La confianza se construyó tras décadas de aprendizaje tras crisis y shocks, lo que condujo al perfeccionamiento de un complejo marco institucional regulatorio y de supervisión. Por el contrario, los humanos parecen menos dispuestos a confiar en los servicios de IA generativa, especialmente en el sector bancario (como se muestra en la misma figura). ¿Afectará la percepción de que la IA podría estar asumiendo el control de muchas decisiones y procesos en el sector bancario a la confianza en los bancos?

En segundo lugar, la IA podría aumentar el riesgo sistémico y la interconexión a una escala nunca antes vista.

De hecho, cuando pensamos en estos dos conceptos, consideramos principalmente las conexiones financieras, como las que exacerbaban el contagio durante la crisis financiera mundial.

Pero la IA y la tecnología en finanzas crean un nuevo tipo de riesgo sistémico, más operativo que financiero. Las instituciones financieras recurren cada vez más a un conjunto común de modelos, muchos de ellos provenientes de consultores y proveedores comunes, lo que genera un mayor "pensamiento colectivo" en la toma de decisiones financieras. Además, los datos se han convertido en uno de los activos más valiosos.²⁷⁴

Tradicionalmente, los bancos han dependido de una gran cantidad de datos, pero no siempre han estado a la vanguardia de la capacidad para procesarlos. Los agentes que concentran la capacidad de almacenar y procesar datos pueden establecer monopolios de información, con importantes implicaciones para la competencia y, en última instancia, para la estabilidad financiera.

²⁷³ Rampini y Viswanathan (2013); Beck et al. (2023).

²⁷⁴ Farboodi y Veldkamp (2023).

¿Cómo debemos pensar la regulación de los diferentes tipos de riesgos a los que están expuestos los bancos?

Se podría argumentar que la IA probablemente ayude a gestionar y mitigar los riesgos en el sector financiero. Los beneficios en el riesgo crediticio ya son visibles, como se muestra ampliamente en el capítulo. El riesgo de mercado y el riesgo de liquidez también pueden beneficiarse del uso de la IA para medir y adaptarse a los riesgos. Pero ¿qué ocurre con el riesgo operacional? Los datos sobre riesgo operacional no son tan generalizados, ya que se refieren principalmente a eventos poco frecuentes. Esto significa que la IA tiene menos capacidad para aprovechar el poder de los datos para realizar contribuciones significativas. Al mismo tiempo, el riesgo operacional en sí mismo se ha convertido en una fuente de riesgo más importante para el sistema financiero, y la ciberseguridad adquiere un papel cada vez más destacado en las preocupaciones de los bancos, agravada por el aumento de los riesgos geopolíticos y los riesgos derivados del cambio climático. Los riesgos sistémicos que plantea el uso de modelos comunes y herramientas de IA se suman a esto.

Si bien la IA puede contribuir a mejorar la capacidad de medir y gestionar el riesgo operacional, podría ser relevante reflexionar sobre el equilibrio entre riesgos y regulación en el sistema financiero. La regulación está diseñada para abordar principalmente los riesgos tradicionales, en particular los de crédito. La regulación sobre riesgo operacional es más contundente y menos específica. Podría justificarse un debate sobre la posibilidad de avanzar hacia una mejor regulación y supervisión de estos riesgos operacionales.

¿Cuáles son las implicaciones de un panorama geopolítico cambiante?

El capítulo concluye con un análisis de los principios para la regulación de la IA en el sistema financiero, lo cual es imposible sin una sólida cooperación internacional. Esto siempre representaría un desafío, pero el panorama geopolítico actual lo hace aún más complejo.

Al preguntarle a ChatGPT: «Como agente de GenAI, ¿cuál es su opinión sobre los riesgos derivados de la situación geopolítica y el uso de la IA en el sistema financiero?», obtuve la siguiente respuesta: «Las tensiones geopolíticas pueden amplificar los riesgos del uso indebido de la IA en el sistema financiero, en particular mediante ciberataques, manipulación económica o campañas de desinformación dirigidas a los mercados. La creciente dependencia del comercio y la evaluación de riesgos impulsados por la IA podría crear vulnerabilidades sistémicas si actores adversarios explotan las debilidades del modelo o la dependencia de los datos. Para mitigar estas amenazas, es esencial una sólida cooperación internacional, una supervisión regulatoria sólida y marcos transparentes de gobernanza de la IA». Parece que tanto humanos como máquinas coincidimos en la necesidad de una sólida cooperación internacional. Las decisiones sobre cómo implementarla aún están en manos de los humanos.

En resumen, este capítulo constituye una contribución notable para comprender mejor un problema novedoso y complejo, con numerosas perspectivas interesantes y novedosas. La IA aporta numerosos beneficios al sector financiero. Sin embargo, inevitablemente, también conlleva riesgos, algunos de ellos imprevisibles. Esto significa que la regulación tiene un papel que desempeñar y que debe basarse en la cooperación internacional. Este es quizás el mayor riesgo.

5.2 DISCUSIÓN DEL CAPÍTULO 2, "INTELIGENCIA ARTIFICIAL Y EL SECTOR FINANCIERO: TRANSFORMACIONES, DESAFÍOS Y RESPUESTAS REGULADORAS", POR RONIT GHOSE

156

La inteligencia artificial (IA) está impulsando un poderoso volante de innovación, con sistemas avanzados que crean una mejor IA, lo que a su vez acelera avances en informática y capacidades a un ritmo sin precedentes.

La IA podría ser la tecnología de propósito general (GPT) de los años 2020 y 2030, transformando profundamente las finanzas y el dinero.

Las GPT transforman economías enteras, alterando nuestra forma de vivir y trabajar. Crean oportunidades de crecimiento e innovación, a menudo mejorando la calidad de vida. Sin embargo, también alteran los sistemas existentes, generando pérdidas a corto plazo y ganancias a largo plazo.

La máquina de vapor mercantilizó la producción y el movimiento físico, impulsando la revolución industrial. Más recientemente, internet revolucionó la comunicación y el intercambio de información. De igual manera, la IA puede complementar o incluso sustituir la inteligencia humana, incluyendo el análisis, la toma de decisiones y la creación de contenido.

Los ciclos tecnológicos anteriores han eliminado empleos y empresas antiguos, al tiempo que han creado otros nuevos. La IA repetirá este ciclo, posiblemente a un ritmo más rápido. El reto que plantea la IA es que podría generar una desigualdad entre un menor número de ganadores (profesionales con un alto potencial de crecimiento y emprendedores de startups de IA) y un mayor número de perdedores (trabajadores promedio, empresas establecidas).

El auge de la IA generativa (GenAI), ejemplificado por el lanzamiento de ChatGPT en noviembre de 2022, marcó un punto de inflexión. GenAI introdujo una interfaz de usuario intuitiva, haciendo la IA accesible a las masas y despertando un amplio interés entre consumidores y tomadores de decisiones.

Creo que la GenAI tiene un potencial revolucionario en los servicios financieros porque el sector es rico en información. Los datos son su materia prima. En muchos sentidos, las finanzas son el sector ideal para la aplicación de la IA.

¿Cómo se utilizará la IA en las finanzas?

Durante años, la IA, en particular el aprendizaje automático (ML), se ha utilizado en finanzas con datos estructurados y para tareas cuantitativas. Hoy en día, se aplica principalmente a la gestión de riesgos y la fijación de precios. GenAI ampliará estos casos de uso.

A corto y mediano plazo, podemos esperar que el mayor impacto en las instituciones financieras tradicionales se dé en las tareas internas y las mejoras de productividad, más que en la introducción de numerosos productos nuevos. Las instituciones tradicionales se centrarán en mejoras en áreas como software y codificación, monitorización de transacciones y cumplimiento normativo, entre otras.

Muchas funciones bancarias, como la suscripción de créditos, el trading algorítmico, la construcción de carteras y la monitorización de transacciones, ya utilizan IA/aprendizaje profundo. La GenAI generará nuevas oportunidades más allá de las mejoras de productividad, pero es probable que parte del trabajo preliminar (productos y servicios más recientes, bots que utilizan dinero tokenizado e IA descentralizada) tarde en desarrollarse y comercializarse.

157

A continuación se muestra una descripción general de los principales casos de uso de IA/GenAI en finanzas:

Programación y software: Los grandes bancos emplean a miles de desarrolladores de software, a menudo entre el 15 % y el 25 % de su plantilla. La IA puede optimizar la programación automatizando tareas repetitivas, optimizando el código y acelerando los ciclos de desarrollo.

Búsqueda y resumen: El sector de servicios financieros se caracteriza por su gran volumen de datos y documentos. La IA puede filtrar grandes conjuntos de datos, extraer información relevante y generar resúmenes concisos que pueden utilizarse como base para una toma de decisiones más rápida y la ejecución de las acciones siguientes.

Monitoreo de transacciones, cumplimiento y conducta: Los sistemas basados en IA pueden destacar en el monitoreo de la conducta externa e interna. Al analizar continuamente las transacciones y el comportamiento, y detectar anomalías en tiempo real, la IA mitiga los riesgos, garantiza el cumplimiento normativo y minimiza las actividades fraudulentas.

Atención al cliente (Chatbot 2.0): Los chatbots impulsados por IA pueden brindar soporte al cliente personalizado las 24 horas, los 7 días de la semana, resolviendo consultas rápidamente con interacciones similares a las humanas.


Riesgo crediticio y suscripción: la IA puede analizar diversos conjuntos de datos tradicionales y no tradicionales para evaluar el riesgo crediticio y facilitar los procesos de suscripción con mayor precisión y velocidad en comparación con los modelos tradicionales.

Investigación de inversiones: La investigación fundamental implica mucha búsqueda y resumen.

de información, conjuntos de datos y generación de texto y gráficos. GenAI puede optimizar el tiempo y los costos al automatizar las tareas de búsqueda y recuperación de información.

Gestión de activos y carteras: la IA puede identificar oportunidades de inversión, optimizar las asignaciones de activos y personalizar carteras a escala, lo que permite a los asesores y gestores de carteras centrarse en actividades de alto valor, como la interacción con el cliente y la generación de alfa.

RESUMEN DE CASOS DE USO DE IA GENERATIVA EN FINANZAS, ADOPCIÓN MÁS AMPLIA ESTIMADA Y IMPACTO POTENCIAL EN LAS TAREAS²⁷⁵



Fuente: Citi GPS (2024).

La próxima frontera: tu propio Jarvis digital

El auge de los agentes autónomos podría marcar el comienzo de una era en la que las personas dependan cada vez más de bots de IA para gestionar sus vidas. En lugar de dar instrucciones breves a los LLM, podemos confiar en asistentes digitales inteligentes con capacidades avanzadas.

Estos bots, equipados con sofisticados algoritmos y con acceso a grandes cantidades de datos, negociarán con sus contrapartes para asegurar las mejores condiciones posibles para los usuarios. Este cambio no solo optimizará los servicios, sino que también garantizará que las decisiones se tomen con un nivel de precisión y previsión que los humanos podrían no tener.

Es posible que los consumidores ya no tengan que dedicar tiempo a recopilar información, comparar diferentes artículos o realizar tareas. En cambio, es probable que se centren en decisiones de sí/no/cambio, mientras la IA se encarga del resto.

Considere las renovaciones de hipotecas: en lugar de buscar tasas manualmente, un agente de IA podría rastrear las fechas de vencimiento de las hipotecas, analizar las condiciones del mercado, comparar productos crediticios, negociar con los prestamistas las condiciones óptimas y automatizar el papeleo. Inicialmente, los usuarios podrían requerir que los agentes de IA soliciten confirmación humana antes de tomar decisiones financieras, pero a medida que aumenta la confianza, se pueden gestionar más tareas de forma autónoma.²⁷⁶

En este nuevo paradigma, la decisión crítica para los consumidores será seleccionar el bot adecuado. Elegir asesores gestionados por bots, al igual que elegir asesores financieros personales humanos, será una tarea clave. Pero ¿para quién trabajarán los bots: para grandes tecnológicas, instituciones de confianza como bancos o startups?

²⁷⁵ Véase el informe de Citi GPS, IA en finanzas: bots, bancos y más allá (Citi GPS, 2024).
²⁷⁶ Véase el informe de Citi GPS, Agentic AI: Finance & the "Do It For Me" Economy (Citi GPS, 2025).

Es probable que los bancos líderes opten por ofrecer sus propios servicios basados en IA. Sin embargo, las grandes tecnológicas pueden tener una ventaja competitiva al ser nativas digitales y tener una mayor velocidad de comercialización. En algunos mercados, también pueden contar con marcas de consumo más sólidas.

Las empresas más pequeñas y las nuevas empresas pueden ver su crecimiento impulsado por el crecimiento de los agentes. La IA puede mejorar drásticamente su alcance. Pero ¿querrán los consumidores dedicar tanto tiempo a pensar qué agente usar? Es probable que optemos por marcas conocidas y de confianza.

Nuevas startups y el futuro del trabajo

A lo largo de la historia, las tecnologías de uso general —la máquina de vapor, la electricidad, internet— han transformado las economías. ¿Desatará la IA otra ola de destrucción creativa o una represión del capitalismo oligárquico actual?

En ciclos anteriores, las revoluciones tecnológicas propiciaron el auge de nuevas empresas. La era de la máquina de vapor vio cómo las grandes fábricas y empresas industriales reemplazaban a las empresas artesanales. La electricidad transformó aún más la producción en masa y la urbanización. La Primera y la Segunda Revolución Industrial marcaron el comienzo de una nueva era para la banca y las entidades financieras.

De igual manera, la era de internet, a partir de la década de 1990, propició el surgimiento de nuevas empresas de comercio electrónico, medios de comunicación y tecnología financiera, mientras que los actores tradicionales tuvieron dificultades para adaptarse. La IA podría seguir un patrón similar. La combinación de la nube, la IA y los agentes podría desencadenar una revolución en la prestación de servicios digitales, incluidas las finanzas.

Así como la computación en la nube transformó la economía del emprendimiento del gasto de capital al gasto operativo, la IA agente la traslada del pago de nóminas a la suscripción de software. Los bancos digitales y las fintechs reguladas podrán aprovechar su infraestructura tecnológica y sus licencias para crecer aún más rápido. Mientras tanto, las grandes empresas financieras podrían actuar con cautela debido a las limitaciones culturales, regulatorias y tecnológicas.

La IA también está transformando el trabajo del conocimiento a gran escala. Al igual que la imprenta democratizó la información, la IA está descentralizando el acceso al conocimiento y la creatividad. Una adopción más amplia de la IA probablemente traerá consigo mejoras de productividad en el sector financiero al automatizar y optimizar las tareas actuales.

Las tareas repetitivas (entrada de datos, informes, cumplimiento normativo) son propicias para la automatización. A medida que la IA avanza, los agentes autónomos permiten que un solo profesional o un pequeño equipo logre lo que antes requería departamentos enteros. Se puede hacer más con menos personal, lo que se traduce en menos personal.

También surgirán nuevos roles, especialmente centrados en el desarrollo de la IA, la ética, la gobernanza y la supervisión. Proliferarán las industrias centradas en la capacitación, el perfeccionamiento y la auditoría de sistemas de IA, lo que convertirá la curación de datos y el control de calidad en áreas de crecimiento cruciales.

Cómo afrontar los posibles peligros de la IA

Si bien la IA promete avances en las finanzas y la productividad económica, también existen desafíos considerables. El lado oscuro de la IA no es solo una distopía especulativa. Los algoritmos pueden reforzar las desigualdades sociales existentes; la GenAI puede difundir desinformación, además de utilizarse para cometer fraudes y ocultar la responsabilidad humana.

Sesgo y discriminación: La IA es tan eficaz como los datos con los que se entrena. Por ejemplo, los modelos de decisión crediticia basados en IA podrían favorecer inadvertidamente a ciertos sectores de la sociedad, lo que podría resultar en un aumento de las disparidades sociales y económicas. Abordar el sesgo algorítmico requiere prestar atención a la recopilación, el preprocesamiento y el diseño de los datos para garantizar la equidad y la inclusión.

Falta de transparencia: Los sistemas de IA pueden ser opacos, lo que dificulta el proceso de toma de decisiones y la lógica subyacente. Esto supone un desafío, ya que los humanos no pueden comprender cómo la IA llegó a su conclusión, lo que genera desconfianza y resistencia a su adopción. La explicabilidad de los modelos de IA es un tema de creciente preocupación, especialmente debido a la creciente adopción de la IA por parte de las empresas y la sociedad.

Desinformación y manipulación: El contenido generado por IA podría contribuir a la difusión masiva de información falsa o engañosa, manipulando la opinión pública, socavando la confianza en fuentes fiables y generando confusión social. Un riesgo particular de la IA es su capacidad para contar historias que resuenen con las creencias y puntos de vista preexistentes de un individuo, lo que refuerza las cámaras de resonancia y los silos ideológicos.

Alucinación: GenAI tiende a alucinar (es decir, a generar información que no se basa en datos reales) pero la presenta como un hecho. La alucinación suele deberse a las limitaciones de los datos de entrenamiento y a la naturaleza probabilística del modelo. Cuando el modelo encuentra una indicación para la que no dispone de datos de entrenamiento suficientes o carece de ellos, crea una respuesta plausible pero incorrecta.

Concentración del mercado: Los modelos de IA utilizados por consumidores, empresas y gobiernos pueden ser proporcionados por un pequeño número de empresas privadas, principalmente con sede en Estados Unidos o China. El dominio de los proveedores de IA puede reflejar la concentración y los riesgos de punto único de fallo que ya existen en la computación en la nube.

Preocupaciones sobre las reservas de talento y los empleos de nivel inicial: muchos trabajos repetitivos corren el riesgo de automatizarse, lo que intensifica la polarización laboral y, potencialmente, la desigualdad económica. Así como la deslocalización y la externalización de empleos administrativos en las últimas décadas plantearon interrogantes sobre las reservas de talento y los empleos de nivel inicial, la IA replanteará el debate, pero esta vez a nivel global. La naturaleza de los roles en los centros de servicios compartidos cambiará.

Ingeniería social amplificada: La Alianza Global Antiestafa estimó un billón de dólares en pérdidas por estafas en 2023. La Agencia Nacional contra el Crimen del Reino Unido clasificó las estafas como la principal forma de delito. La IA introduce nuevos riesgos de ciberseguridad a medida que los actores maliciosos aprovechan sus capacidades para lanzar ciberataques más sofisticados y personalizados. IA avanzada.

Los algoritmos podrían ser explotados por actores maliciosos para evadir los métodos de detección tradicionales utilizando malware impulsado por GenAI que adapta su comportamiento en función de las defensas del objetivo.

Actualmente, la mitad de todo el tráfico en línea consiste en actividad de bots, muchos de ellos maliciosos.²⁷⁷ A medida que la IA avanza, podríamos ver un aumento en las estafas sofisticadas impulsadas por IA.

Estafas de deepfakes generadas por IA: La IA puede generar audio, imágenes o texto humano que no es real. Hoy en día, el audio generado por IA ya ha superado ese límite inquietante, convirtiéndose en imperceptible para el oído humano; el vídeo generado por IA está mejorando rápidamente. La IA agente conducirá a la producción y distribución masiva de deepfakes. En el ámbito financiero, esto podría utilizarse para manipular transacciones, crear fraudes de identidad sintética y automatizar las estafas. En 2025, cabe esperar un aumento de las suplantaciones de identidad basadas en audio y vídeo debido a la democratización de GenAI, lo que permitirá a los actores maliciosos suplantar la identidad de personas conocidas, como compañeros, clientes, familiares, políticos y actores. Desde la perspectiva de los bancos, el riesgo y las implicaciones de las amenazas de las suplantaciones de identidad basadas en GenAI son tangibles hoy y se acelerarán este año.

161

Discusiones

5.3 DISCUSIÓN DEL CAPÍTULO 3, "EL IMPACTO DE LA IA EN LAS FINANZAS: LA REFORMULACIÓN DE LA INFORMACIÓN Y SUS CONSECUENCIAS", POR ROBIN L. LUMSDAINE

Disfruté muchísimo leyendo este capítulo. Partiendo de la premisa de que gran parte de las finanzas se basa en la información, argumenta que la combinación de IA y la abundancia de datos está transformando la disciplina mediante una mayor eficiencia en el procesamiento de la información y una mayor transparencia en su intercambio. A continuación, analiza sistemáticamente cómo diversos participantes del mercado financiero (creadores de mercado, corredores, gestores de activos) se beneficiarán de esta «revolución de la IA», antes de advertir sobre ciertas fricciones que podrían frenar esta transformación. Entre estas fricciones se destacan la producción de información de bajo valor social, un posible aumento de la asimetría tanto informativa como, por ende, del poder de mercado, y una mayor fragilidad del mercado debido a la naturaleza de caja negra de la mayoría de los modelos de IA.

¿Evolución o revolución?

El capítulo describe el creciente uso de la IA para procesar y extraer información de cantidades cada vez mayores de datos («abundancia de datos») como una «evolución» o una «revolución», indistintamente. Esta distinción es importante, no como una nimiedad semántica, sino en términos de cómo concebimos la capacidad de adaptación de los afectados (humanos, empresas, organizaciones, regulaciones). Cuando pensamos en una revolución, pensamos en un cambio repentino, rápido y disruptivo²⁷⁸; en un contexto económico, es un cambio que altera la trayectoria futura del crecimiento económico y

²⁷⁷ Imperva (2024).

²⁷⁸ Por ejemplo, «una transformación rápida y fundamental» (Wikipedia); «un cambio repentino, extremo o completo en la forma la gente vive, trabaja, etc.» (Britannica),

Desarrollo. Cuando pensamos en la evolución, pensamos en una transformación más gradual que ocurre durante un período prolongado, de modo que el cambio a menudo solo se reconoce en retrospectiva.²⁷⁹ Una evolución es un cambio permanente; una revolución es poco frecuente, pero episódica: un cambio permanente percibido hasta que llega la siguiente.

Las implicaciones de este cambio para las finanzas aún no están claras. Hay una frase importante en el segundo párrafo del capítulo: «Por el contrario, si estas tecnologías degradan la calidad de la información financiera, esto sería motivo de preocupación y podría justificar la intervención política». Esto plantea una pregunta clave al considerar en qué medida la confluencia de la IA y la abundancia de datos beneficiará al sector financiero.

¿Mejora la abundancia de datos la calidad de la información? ¿Es siempre mejor tener más?

Cuando pienso en la cantidad de información disponible ahora en comparación con cuando comencé mi carrera, es realmente una época emocionante de inmensa abundancia de datos. Pero al pensar en procesar esa información de forma significativa —por ejemplo, para comprender la complejidad de los mercados financieros actuales o para pronosticar los precios de los activos—, esa emoción se convierte rápidamente en una sobrecarga de información.

Relación señal-ruido

El capítulo comienza con lo que describe como los "tres pilares de la revolución del big data en las finanzas": abundancia de datos, técnicas para convertirlos en decisiones y el aumento de la potencia informática. Argumenta que estos factores reducen el coste de producción de información. Continúa describiendo cómo este aumento de la información genera señales más precisas en los mercados financieros y, por consiguiente, una mejor toma de decisiones. Sin embargo, podría argumentar que lo que se reduce no es el coste de producción de información, sino el de análisis de la misma, y que aún está por verse si dicho análisis resulta en la producción de información adicional o simplemente en la síntesis o reorganización de la información existente.

Me pareció que el capítulo guardaba cierto silencio sobre la cuestión de la calidad de la información, a pesar de su análisis de posibles «fallas del mercado» o fricciones que inhiben las ganancias de eficiencia previstas, lo que resulta en posibles efectos desestabilizadores. Hay indicios de que la calidad de la información es importante, como la referencia a la posibilidad de información con bajo valor social. No cabe duda de que la IA ha permitido el procesamiento de grandes cantidades de información, más allá de lo que los humanos (o incluso las máquinas anteriormente) podían procesar.²⁸⁰ Pero más no es necesariamente mejor; no es solo la cantidad de información lo que importa, sino la calidad. En concreto, es importante garantizar que cualquier información añadida aumente nuestra relación señal-ruido, o al menos no la reduzca. Ahora bien, muchos argumentarían que

²⁷⁹ Por ejemplo, "Un proceso gradual en el que algo cambia..." (American Heritage Dictionary); "un proceso gradual de cambio y desarrollo" (Cambridge Dictionary); "un proceso de cambio gradual que tiene lugar a lo largo de muchas generaciones" (Collins Dictionary).

²⁸⁰ En una encuesta ad hoc a los participantes en el seminario "AI Frontiers in Finance" de Oliver Giesecke sobre "Aprendizaje profundo para En el seminario "Bonos corporativos" del 11 de marzo de 2025, organizado por el organizador del seminario Sascha Steffen, al inicio del mismo, el 55 % de los encuestados eligió "un procesamiento más eficiente de grandes conjuntos de datos" como la "mayor ventaja de utilizar técnicas de aprendizaje profundo en la inversión en bonos".

La posibilidad de encontrar una pieza clave de información es aún mayor cuanto mayor sea la información que se procesa. Esto es cierto si la información que buscamos no se encuentra en el conjunto original. Sin embargo, yo diría que el beneficio de más información depende de la probabilidad de encontrar esa pieza clave. Encontrar una aguja en un pajar ya es bastante difícil, sin tener que separar más paja. Por lo tanto, es importante reflexionar y considerar el valor añadido que se obtiene.

163

Podría decirse que, si nuestra relación señal-ruido ya es alta (es decir, tenemos mucha señal), la mejora marginal derivada del procesamiento de información adicional es menor que si seguimos buscando la señal. Dicho de otro modo, en cualquier momento dado, lo que esperamos es operar con base en la señal, no en el ruido.

Discusiones

Los comerciantes comercian

Consideremos ahora la agregación de esos puntos temporales en un día típico de negociación. Cuando trabajaba en el sector privado, observé que los operadores están constantemente mirando sus pantallas, mirando los precios, esperando una oportunidad para operar. Por lo tanto, me he preguntado si el procesamiento eficiente de la información realmente beneficia el funcionamiento de los mercados. En concreto, si dividimos el tiempo disponible del día entre el tiempo con información y el tiempo sin ella, un procesamiento/incorporación más rápido de la información implicaría que una mayor proporción del día no contiene información. Por lo tanto, si aceptamos que los operadores operan, esto significa que una mayor proporción de operaciones se basará en el ruido.

Rendimiento pasado...

Todos conocemos el dicho: «El rendimiento pasado no es necesariamente un indicador de la rentabilidad futura». Todos los modelos de IA existentes se entrenan con información pasada. Pero el capítulo señala que «Brogaard y Zareei (2023) utilizan algoritmos de aprendizaje automático para encontrar reglas de trading rentables basadas en la rentabilidad pasada». ¿Cómo es posible?

La llegada de las técnicas generativas ha aumentado la esperanza de que algún día la IA pueda ofrecer el mismo tipo de pensamiento innovador que un humano, lo que se traducirá en resultados superiores. Pero que la información sea nueva para nosotros no significa que sea realmente nueva. Esto me recuerda algunas de las preguntas fundamentales con las que los científicos se han enfrentado durante años: ¿se puede generar algo (ya sea energía o materia) de la nada?

La respuesta es parcialmente afirmativa, si analizamos detenidamente el conjunto de información en el que se basan las decisiones. El grado de eficiencia de los mercados depende fundamentalmente del conjunto de información que se considere. Los investigadores del precio de los activos podrían analizar esto en función de si los factores conocidos aún abarcan el espacio de un conjunto de información en constante crecimiento o si la información generada por IA requiere la existencia de uno o más factores nuevos; los participantes del mercado podrían debatir de forma similar si la información generada por IA produce alfa.

Sin embargo, el riesgo de asimetrías de información que señala la Sección 3 da lugar a que algunos participantes posean información pseudoprivada. En ese sentido, la capacidad de algunos participantes para procesar (aunque no necesariamente producir) información adicional podría otorgarles una ventaja, independientemente de su calidad, especialmente cuando se combina con la capacidad de realizar operaciones importantes que impulsen el mercado basándose en ella.

Dado que la mayoría de los algoritmos se entrenan principalmente con información existente o pasada, es difícil prever cómo se crea nueva información. Además, cada vez hay más pruebas de que las máquinas no extrapolan bien. Una nota al pie del capítulo parece reconocerlo, señalando que los algoritmos de IA tienden a no funcionar bien cuando se enfrentan a situaciones muy diferentes de los datos subyacentes con los que fueron entrenados.

Sesgo de información/persuasión correlacionado

El riesgo de que la información generada por IA se perciba como nueva cuando, en realidad, simplemente está reempaquetada o, como mucho, altamente correlacionada con información conocida, recuerda el artículo fundamental sobre el sesgo de persuasión de DeMarzo et al. (2003). Su modelo teórico destaca la idea de que las personas que escuchan la misma información de múltiples fuentes no tienen en cuenta que puede provenir de la misma fuente única; es decir, no ajustan adecuadamente la información correlacionada.²⁸¹ Este resultado se ha demostrado empíricamente en numerosos estudios.²⁸²

Será interesante ver si la información generada por IA sufre de un sesgo similar.

En principio, un algoritmo de IA puede programarse para considerar correctamente la correlación de la información, suponiendo que dicha correlación pueda medirse con precisión. Sin embargo, esto podría no ser así para quienes toman decisiones que utilizan mayores cantidades de dicha información en un entorno cada vez más abundante en datos.

En cierto modo, la correlación es útil. La previsibilidad se basa en cierta capacidad para aprovechar la experiencia pasada. Sin embargo, un exceso de correlación puede generar reacciones persistentes. El aprendizaje por refuerzo intenta equilibrar esa tensión inherente. Es posible que un algoritmo pueda lograr ese equilibrio con mayor fiabilidad que un humano.

Otros sesgos conductuales

Cabe mencionar otros dos patrones de comportamiento. El capítulo cita varias razones por las que la abundancia de datos puede desviar la atención de la información y la predicción a largo plazo hacia una perspectiva más a corto plazo. Esta posible rotación de la curva de información sugiere un sesgo presente inherente (¿o acentuado?) que puede o no conducir a una toma de decisiones óptima.

281 Este patrón de comportamiento se ha denominado "negligencia de correlación" en la literatura posterior (por ejemplo, Levy y Razon, 2015; Bohren, 2016; Levy et al., 2022).

282 Véase, por ejemplo, Brandts et al. (2015) y Enke y Zimmermann (2019).

Al comienzo de esta discusión, mencioné la posibilidad de una sobrecarga de información.

El capítulo reconoce una compensación inherente que las personas deben hacer ante la creciente cantidad de información, señalando que, “al tomar estas decisiones, los intermediarios sopesan su beneficio privado de asignar capacidad informativa adicional a un tipo de información contra su costo privado de estar menos informados sobre otro tipo”. Teniendo en cuenta esta capacidad de atención limitada, la velocidad de procesamiento que ofrece la IA puede, de hecho, ayudar a identificar más rápidamente un resultado deseado.²⁸³

Percepciones versus realidad

Gran parte de mi investigación se ha centrado en la distinción entre las percepciones de las personas y la información basada en datos, en parte porque, en muchas circunstancias, no son necesariamente estas últimas las que impulsan las decisiones, sino las primeras.²⁸⁴ Las percepciones pueden conducir a una realidad autocumplida. En ese sentido, la pregunta no es realmente si la IA produce nueva información o no, sino si la gente cree que lo hace.²⁸⁵

La percepción también es resultado del procesamiento de la información. A medida que esta tarea se asigna cada vez más a la IA y las decisiones se basan en sus aportaciones, corremos el riesgo de que sean las percepciones de la IA las que se reflejen en los precios del mercado, y no las nuestras. Muchos de nosotros ya hemos experimentado algo similar con estudiantes que utilizan herramientas de IA en sus escritos. Resulta difícil determinar de quién son las percepciones que refleja el texto. Lo mismo ocurrirá al considerar los precios del mercado: no solo reflejarán información, sino también la percepción de dicha información, tal como la interpreta la IA.

Una crítica frecuente a quienes buscan involucrar algoritmos en la toma de decisiones es que muchos de ellos son una «caja negra», es decir, algo que no se comprende bien. El capítulo también señala que el creciente uso de la IA para procesar información crea un riesgo (operativo) adicional, debido a la incapacidad de los humanos para comprender plenamente el proceso de toma de decisiones del algoritmo. Dada nuestra naturaleza humana de desconfiar de las cosas que no comprendemos del todo (un comportamiento aprendido desde la infancia),²⁸⁶

La IA tiene entonces el potencial de crear un círculo vicioso y sin fin, mediante el cual construimos modelos cada vez más complejos para procesar cantidades mayores de información, generando quizás más información que luego requiere más complejidad para tratar de comprenderla.

Pero otros señalarán ejemplos reales en los que estamos dispuestos a aceptar cosas que no entendemos, en parte porque han sido validadas o se ha demostrado su fiabilidad. Muchos usamos medios de transporte que no comprendemos del todo. Entonces, ¿cuán diferente es nuestra capacidad para comprender el proceso de toma de decisiones de un algoritmo de nuestra capacidad para comprender plenamente el de un humano?

²⁸³ Para un análisis de la atención limitada, véase, por ejemplo, Hirshleifer y Teoh (2003) y Gabaix et al. (2006).

²⁸⁴ Bassett y Lumsdaine (2001); Lumsdaine y Potter van Loon (2018).

²⁸⁵ Véase también Greenwich Associates (2017).

²⁸⁶ Reimann et al. (2017) encuentran que si bien la confianza es un rasgo hereditario, la desconfianza se aprende.

Preferencia por los humanos

Parecemos tener una clara preferencia por los humanos, particularmente cuando se trata de decisiones.

El capítulo enfatiza una “clara división del trabajo: las máquinas evalúan la probabilidad de varios resultados y los humanos usan esta evaluación para tomar decisiones”, pero señala que esto

La división de tareas se está desdibujando, en particular con los avances en el aprendizaje por refuerzo.²⁸⁷ Sin embargo, existen numerosas razones para pensar que la IA podría, de hecho, superar a la IA, como señala el capítulo. Por un lado, la IA podría mostrar menos sesgos cognitivos que un humano. Además, citando evidencia de que la combinación de pronósticos humanos y de aprendizaje automático (AA) es mejor que el AA solo, el capítulo infiere que «los humanos poseen habilidades únicas para elaborar pronósticos». Sin embargo, existe una amplia literatura que documenta que la combinación de pronósticos generados estadísticamente resulta en una mayor precisión que un solo pronóstico, por lo que no está claro que las ganancias sean específicas de la inclusión de un pronóstico humano.²⁸⁸

Nuestra preferencia por los humanos se ilustra en el hecho de que la mayoría de nuestras regulaciones actuales se basan en respuestas humanas (por ejemplo, la demostración de comunicación o intención para determinar la responsabilidad). ¿No constituye esto en sí mismo un sesgo conductual? ¿Por qué deberíamos preferir a los responsables de la toma de decisiones humanos? Los humanos tienen cierto grado de responsabilidad, mientras que los algoritmos no. Las iniciativas regulatorias actuales intentan abordar esta discrepancia, por ejemplo, atribuyendo la responsabilidad a los proveedores de modelos de IA (la Ley de IA de la UE) y enfatizando la necesidad de controles y gobernanza adecuados, con suficiente supervisión humana: el requisito de «participación humana».

Los humanos somos la caja negra definitiva

Vale la pena enfatizar que los humanos son la caja negra definitiva. Y, sin embargo, nos sentimos cómodos con su aportación. Entonces, ¿a qué se debe esto? Una razón clave es la confianza. Existe una amplia literatura que documenta que la forma en que las personas desarrollan y mantienen la confianza en los humanos y las máquinas difiere.²⁸⁹ Además, los errores se perdonan más fácilmente cuando son cometidos por un humano, mientras que la confianza se abandona más rápidamente cuando el error es algorítmico.²⁹⁰ La sección 3.2 habla sobre el riesgo de que la IA amplifique las asimetrías de información: la confianza podría ser un mecanismo clave a través del cual se amplificará.

En un mundo con abundancia de datos, es importante garantizar que la información en la que se basan las decisiones sea precisa y fiable, independientemente de si la genera un ser humano o una IA. Queda por ver si los sesgos de comportamiento que se observan comúnmente en los seres humanos, como la excesiva confianza en la experiencia pasada y la persuasión...

287 Véase, por ejemplo, Dou et al. (2023).

288 Véase Timmermann (2006) y Wang et al. (2023) para encuestas sobre combinación de pronósticos.

289 Hoff y Bashir (2015); Cabbidu et al. (2022); Chugarova y Luhan (2022).

290 Dietvorst y cols. (2015, 2018).

El sesgo, la negligencia en la correlación, la atención limitada y la preferencia por los humanos también estarán presentes en el entorno de la IA. Los beneficios de la IA para las finanzas, así como los riesgos, dependerán fundamentalmente de la calidad de la información generada y de si se puede mantener una alta relación señal-ruido.

5.4 DISCUSIÓN DEL CAPÍTULO 4, "FINANZAS CORPORATIVAS Y GOBIERNO CON INTELIGENCIA ARTIFICIAL: ANTIGUAS Y NUEVAS", POR SEAN CAO

Este capítulo explora la frontera entre la inteligencia artificial y el gobierno corporativo. Como artículo de revisión, se aleja de la ejecución empírica y, en cambio, presenta perspectivas conceptuales de alto nivel destinadas a estimular la reflexión y guiar la investigación futura. Mi análisis busca profundizar en los puntos clave, basándose en ejemplos, observaciones del sector y trabajos académicos relacionados para fomentar una participación significativa.

Según mi experiencia revisando investigaciones, los estudios relacionados con la IA se pueden clasificar generalmente en tres tipos. El tipo 1 es metodológico y utiliza la IA como herramienta para responder a preguntas tradicionales. Por ejemplo, los investigadores podrían usar el aprendizaje automático para predecir reexpresiones o rentabilidades, temas convencionales mejorados con métodos novedosos. El tipo 2 aborda preguntas fundamentalmente nuevas que surgen específicamente debido a la existencia e influencia de la IA. Estas preguntas incorporan inherentemente la IA, como: ¿Cómo colaboran los humanos con la IA? ¿Cómo asignan tareas los ejecutivos corporativos entre los agentes de IA y los humanos? El tipo 3 se centra en cuestiones de políticas de IA y examina cómo la IA está transformando la gobernanza corporativa, un área cada vez más influenciada por desafíos sociales complejos. El presente capítulo se enmarca principalmente en el tipo 2, con cierta conexión con el tipo 3.

Nuevos límites de la asimetría de la información: asimetría de la información pública

El primer punto destacado del capítulo se refiere a un cambio en la definición y los límites de la asimetría de la información. Tradicionalmente, este concepto se refería a la brecha de conocimiento entre los inversores internos y externos. Consideremos el caso de Tesla: los inversores internos poseían datos de producción privados de los que carecían los inversores externos. Sin embargo, con la llegada de la IA, esta brecha se está reduciendo. Un ejemplo notable del capítulo relata cómo, en 2017, analistas externos utilizaron imágenes satelitales para estimar la producción del Model 3 de Tesla. Este tipo de datos alternativos, procesados por IA, permitió a los externos aproximarse al conocimiento previamente exclusivo de los inversores internos. En este caso, la IA reduce la asimetría de la información tradicional.

Sin embargo, si bien la IA reduce una brecha, amplía otra. El capítulo introduce el novedoso concepto de «asimetría de la información pública», que se refiere a las disparidades entre partes externas que, técnicamente, tienen el mismo acceso a los datos públicos. La brecha ahora no radica en el acceso a la información, sino en la capacidad para procesarla. Un analista con recursos de IA puede extraer información de imágenes satelitales o información financiera compleja que un inversor minorista no puede. Por lo tanto, surge una nueva brecha de información entre los externos.

La asimetría ya no se debe a la exclusividad de la información, sino a la desigualdad en la capacidad para interpretar datos compartidos. Los analistas y las instituciones con acceso a modelos avanzados pueden actuar con información que los inversores minoristas no pueden procesar en la práctica, a pesar de que ambos tienen acceso teórico. Este concepto redefine la equidad en los mercados financieros.

168

Antes la preocupación era el acceso; ahora, es la capacidad.

Varios artículos profundizan en esta idea. Uno de ellos es Cao et al. (2024), que presenta evidencia empírica de que los analistas que utilizan IA pueden aprovechar mejor los datos alternativos, lo que resulta en resultados comerciales ventajosos. Otro es Cao et al. (2025), que estudia datos visuales de presentaciones de directores ejecutivos. El equipo extrajo imágenes de presentaciones ejecutivas, que incluyen fotos de plantas de producción, propiedades o planos de construcción, y examinó su valor informativo.

Los investigadores clasificaron estas imágenes utilizando un modelo de visión amplia, distinguiendo entre las que representaban operaciones pasadas, planes futuros, pronósticos o imágenes generales. A continuación, clasificaron a los inversores en tres grupos. En primer lugar, los inversores institucionales con IA cuentan con talento y recursos internos, lo que les permite operar eficazmente con señales basadas en imágenes. En segundo lugar, los inversores institucionales sin IA, aunque no utilizan dichas imágenes, mantienen rentabilidades competitivas gracias a su sofisticación general. En tercer lugar, los inversores minoristas, que carecen de acceso a las capacidades de IA, quedan prácticamente excluidos de esta ventaja informativa.

A pesar del acceso equitativo a las presentaciones de los directores ejecutivos, solo ciertos inversores pueden procesar estos datos y actuar sobre ellos. Esta es la esencia de la asimetría de la información pública, que es una brecha basada no en el acceso, sino en la capacidad de procesamiento. Se trata de un cambio drástico con graves implicaciones para la renta variable en los mercados de capitales.

Una solución propuesta es mejorar la accesibilidad de la IA. Si bien muchos se centran en desarrollar mejores modelos, pocos abordan la accesibilidad de estas herramientas. Tomemos como ejemplo BERT y ChatGPT de Google: ambos son potentes, pero la interfaz web de ChatGPT los hace mucho más accesibles. BERT, aunque lanzado antes, sigue siendo relativamente desconocido fuera del ámbito técnico debido a su complejidad de programación. La accesibilidad es fundamental. Las herramientas fáciles de usar pueden democratizar el procesamiento de la información y mitigar la asimetría de la información pública.

Responsabilidad de la IA

El segundo punto clave analizado se refiere a la rendición de cuentas en materia de IA, en particular en el contexto de las empresas de inversión que la integran activamente en sus flujos de trabajo operativos. Para aclarar qué significa la rendición de cuentas en materia de IA en la práctica, podemos examinar una tendencia observada en empresas de inversión medianas que revela tanto las crecientes capacidades de la IA como la persistente necesidad de supervisión humana.

Un flujo de trabajo de inversión típico en estas empresas consta de cuatro etapas principales: selección de acciones, análisis fundamental, gestión de riesgos y ejecución de operaciones. En la etapa inicial, muchas empresas ya han implementado sistemas de IA para identificar posibles oportunidades de inversión. Estas herramientas basadas en IA se utilizan para generar una lista de acciones preseleccionadas basada en modelos cuantitativos y algoritmos propios.

La segunda etapa involucra a analistas humanos que actúan como guardianes. Si bien la IA puede generar una lista de acciones recomendadas, no todas las selecciones son viables. Los analistas humanos realizan una evaluación negativa para identificar señales de alerta que la IA podría pasar por alto. Se basan en el análisis fundamental para validar las selecciones generadas por la IA y garantizar que se excluyan las acciones riesgosas o inapropiadas. Este proceso es crucial, ya que pasar por alto ciertos riesgos cualitativos o contextuales podría comprometer la integridad de la cartera de inversiones.

La tercera etapa se centra en la gestión de riesgos. En ella, otro equipo evalúa cómo la incorporación de una nueva acción afecta la volatilidad general y la exposición al riesgo de la cartera.

Su objetivo es mantener un perfil de riesgo equilibrado y evitar fluctuaciones extremas que podrían derivar de una mala selección de valores. La etapa final aborda las cuestiones de microestructura, donde las empresas buscan minimizar los costes de negociación y optimizar las estrategias de ejecución.

La IA actualmente es más prominente en la primera etapa, pero su rol se está expandiendo a la segunda y tercera. Las empresas están comenzando a utilizar grandes modelos de lenguaje entrenados con décadas de notas de analistas. Estas notas contienen información detallada sobre cómo identificar señales de alerta y evaluar acciones. En otras palabras, documentan los procesos de razonamiento y los patrones de toma de decisiones de profesionales experimentados. Al aprender de estos conocimientos, los sistemas de IA están evolucionando hacia lo que podríamos denominar fundamentalistas de la IA, capaces no solo de generar listas de acciones, sino también de realizar las funciones críticas de control que antes estaban reservadas a los humanos.

Una transformación similar se está produciendo en la gestión de riesgos. Las empresas están entrenando sistemas de IA en estrategias históricas de evaluación de riesgos, lo que les permite desarrollar mecanismos de control de riesgos basados en IA. En ambos casos, la implementación de la IA genera una eficiencia operativa significativa. Por ejemplo, equipos que antes requerían 20 analistas y 10 gestores de riesgos ahora pueden funcionar con tan solo una o dos personas supervisando los sistemas de IA. Este cambio ofrece ahorros en costes laborales y oportunidades de expansión empresarial sin necesidad de aumentar proporcionalmente los recursos humanos.

Sin embargo, surge una pregunta: ¿Por qué la posición sigue en manos de una persona real tras la automatización con IA? Una posible razón es que el individuo aún desempeña un papel funcional, pudiendo tomar mejores decisiones que la IA al actuar como guardián. Otra razón se refiere a la rendición de cuentas. Si bien la IA puede replicar muchos aspectos del razonamiento analítico e incluso superarlo en algunos casos, no puede asumir responsabilidad legal ni ética.

A pesar de las crecientes capacidades de la IA, las empresas mantienen constantemente al menos a un humano involucrado. Directores, directores ejecutivos y gerentes deben asumir personalmente la responsabilidad de las decisiones tomadas bajo su supervisión, incluso cuando estas sean respaldadas o ejecutadas por sistemas de IA. Esto refleja un problema más amplio en el gobierno corporativo, donde la delegación de la toma de decisiones a la IA debe equilibrarse cuidadosamente con la necesidad de responsabilidad y supervisión humanas. La idea de que «la IA puede hacerlo todo por ti, pero no puede ir a la cárcel por ti» se destaca en el capítulo para ilustrar la continua necesidad de responsabilidad humana.

El problema de la desalineación en la agencia de IA

El tercer punto destacado es el problema de la desalineación en la agencia de IA. Esto se refiere a una desconexión entre lo que optimizan los sistemas de IA y lo que los humanos realmente desean.

Para que los sistemas de IA funcionen eficazmente, requieren objetivos claramente definidos, a menudo operacionalizados como etiquetas de "verdad fundamental" en contextos de aprendizaje supervisado. Este requisito se cumple fácilmente en tareas bien estructuradas, como la predicción de la rentabilidad de las acciones, donde la variable objetivo (rentabilidades futuras) es explícita y cuantificable, lo que permite que los modelos se optimicen minimizando el error de predicción de forma rigurosa.

Sin embargo, muchas decisiones de gobierno corporativo son ambiguas. ¿Debería una empresa priorizar el valor para el accionista, el cumplimiento de los criterios ESG o los estándares éticos? ¿Qué peso debería darse a cada uno? Los propios humanos a menudo carecen de consenso sobre estos objetivos, lo que hace casi imposible entrenar la IA eficazmente.

Para que la IA apoye la toma de decisiones en el gobierno corporativo, primero debemos articular objetivos claros. Sin ello, los modelos se optimizarán con métricas erróneas, generando resultados que se desvían de los intereses sociales o a largo plazo más amplios.

Este es un desafío fundamental. En ingeniería, los problemas están bien definidos. En ciencias sociales, la ambigüedad prevalece. A diferencia de los lanzamientos de cohetes, la toma de decisiones humana implica múltiples objetivos contradictorios.

Esta complejidad es nuestra oportunidad. Los investigadores de ciencias sociales deben definir las realidades fundamentales que la IA debe optimizar. No debemos asumir que los resultados de la IA son intrínsecamente correctos. Reflejan los objetivos que les proporcionamos. Unos objetivos mal definidos producen resultados poco alineados.

Muchos estudios financieros y contables existentes asumen que los resultados generados por IA son la norma. Sin embargo, si el modelo se entrenó con datos ambiguos o inconsistentes, sus predicciones podrían reforzar prácticas erróneas.

Debemos replantearnos los datos de formación en el gobierno corporativo. ¿Qué decisiones son correctas?

Las decisiones históricas de la junta directiva pueden ser inconsistentes o estar motivadas políticamente. Sin claridad, corremos el riesgo de enseñarle a la IA lecciones equivocadas.

En futuras investigaciones, los investigadores podrían explorar cómo los diseños experimentales o los entornos de gobernanza simulados podrían contribuir a generar muestras de entrenamiento más limpias. Como alternativa, los modelos de conjunto que incorporan las perspectivas de múltiples partes interesadas pueden ofrecer un enfoque más equilibrado para la optimización.

Otras reflexiones: ¿Quién debería abordar la IA y la gobernanza?

Esto nos lleva a una reflexión final: ¿Deberían los informáticos o los expertos en finanzas abordar los desafíos de la IA y la gobernanza? El desarrollo de la IA depende fundamentalmente de tres pilares interrelacionados. El primero es el diseño de algoritmos, ya que la mayoría de los modelos e innovaciones fundamentales, como los transformadores, están disponibles en plataformas de código abierto.

El segundo es la capacidad computacional, cada vez más accesible gracias a los servicios en la nube que ofrecen una infraestructura escalable. El tercer pilar, y posiblemente el más crucial, es el conocimiento del dominio, que implica una comprensión profunda de los datos institucionales, los contextos organizacionales y los marcos regulatorios. Es en esta tercera área donde los académicos de contabilidad y finanzas pueden realizar las contribuciones más destacadas.

Aquí es donde los académicos de contabilidad y finanzas deben liderar. Consideren datos específicos del dominio, como presentaciones de directores ejecutivos o informes de analistas. Los académicos de informática, sin familiaridad con este contexto, pueden pasar por alto matices clave.

Incluso en nuestro campo, esto requiere una amplia experiencia. Por ejemplo, identificar imágenes en las diapositivas de un director ejecutivo que indiquen crecimiento futuro exige conocimiento de la información financiera, no solo habilidades técnicas.

La IA es cada vez más accesible. Modelos preentrenados como GPT y alternativas de código abierto como Lema permiten a los académicos trabajar con IA sin necesidad de conocimientos avanzados de programación. La barrera de entrada es más baja que nunca. Lo importante ahora es plantear preguntas significativas y comprender los detalles institucionales.

Educar a la próxima generación también es crucial. Un libro de texto gratuito, coescrito por Wei Jiang y por mí, busca abordar este tema, haciendo hincapié en el conocimiento institucional, la alfabetización de datos y las aplicaciones prácticas de grandes modelos en contextos financieros.

De cara al futuro, la colaboración entre finanzas, derecho y informática puede ayudar a desarrollar mejores marcos para la adopción de IA en la gobernanza.

Conclusión

La IA está transformando la gobernanza corporativa de tres maneras clave: redefine la asimetría de la información al crear disparidades en el procesamiento de datos, desafía la rendición de cuentas, ya que no puede asumir responsabilidad legal, y plantea inquietudes sobre la falta de alineación cuando los objetivos humanos son ambiguos.

Estos problemas van más allá del diseño técnico y requieren experiencia en contextos institucionales y criterio humano. Los expertos en finanzas y contabilidad están bien capacitados para liderar este trabajo, gracias a su profundo conocimiento de los datos financieros, las prácticas organizacionales y los entornos regulatorios.

172

En lugar de tratar la IA como una herramienta para resolver viejas preguntas, los investigadores deben examinar cómo esta redefine las propias preguntas. Este capítulo exige una mayor reflexión para guiar la integración de la IA con rigor y perspicacia.

5.5 DISCUSIÓN DEL CAPÍTULO 4, "FINANZAS CORPORATIVAS Y GOBIERNO CON INTELIGENCIA ARTIFICIAL: ANTIGUAS Y NUEVAS", POR LUCA ENRIQUES²⁹¹

Este comentario examina las tensiones y reflexiones presentadas en el capítulo 4 del informe.

El capítulo ofrece un análisis exhaustivo de cómo las tecnologías de inteligencia artificial están transformando el gobierno corporativo y la dinámica del mercado. Sin embargo, varios matices merecen un análisis más profundo. En primer lugar, mis comentarios se centran en lo que considero un aspecto descuidado en el capítulo: la IA como herramienta para optimizar el oportunismo gerencial. En segundo lugar, este comentario pone en duda la idea de que la armonización global sea la mejor manera de abordar los desafíos políticos de la IA en finanzas, en particular en lo que respecta al gobierno corporativo y las asimetrías de información en los mercados públicos. En tercer lugar, ofrece una visión más optimista del impacto en la eficiencia del mercado de las nuevas asimetrías de información que el capítulo identifica.

El problema de la agencia revisitado: la IA como herramienta para el oportunismo gerencial

El capítulo describe eficazmente cómo los sistemas de IA introducen nuevos problemas de agencia al actuar como oráculos, agentes o soberanos, centrándose principalmente en la discrepancia entre los objetivos programados de la IA y los resultados esperados por los directores. Sin embargo, pasa por alto una dimensión crítica del problema de agencia: el potencial de la IA para convertirse en un instrumento para el oportunismo gerencial.

Si bien el capítulo señala correctamente que los sistemas de IA en sí mismos no presentan riesgo moral en el sentido tradicional de buscar beneficios personales, no aborda adecuadamente cómo los agentes humanos (en particular, los directivos) podrían aprovechar estas tecnologías para optimizar sus propios objetivos en lugar de los de los accionistas. La idea fundamental que falta en el capítulo es que, a menos que los intereses humanos y los de los accionistas estén perfectamente alineados, es más probable que la IA, al ser una herramienta controlada por los directivos, se implemente al servicio de los intereses gerenciales.²⁹²

²⁹¹ Este texto ha sido elaborado con la ayuda de Claude.ai a partir de las diapositivas del autor para el taller del IESE donde se discutió el informe.

²⁹² Enriques y Zetzsche (2020).

La selección de los datos de entrada, la definición de objetivos y la implementación de sistemas de IA en las estructuras corporativas permanecen bajo el control de la gerencia. Esto crea un problema de metaagencia, donde el diseño y la implementación de las herramientas de IA se ven sujetos a los mismos conflictos de agencia que analiza el capítulo. Por ejemplo, los gerentes podrían introducir datos selectivamente en los LLM o personalizar parámetros algorítmicos para validar sus estrategias preferidas u ocultar el bajo rendimiento, manteniendo al mismo tiempo la apariencia de objetividad basada en datos.

El análisis de este capítulo sobre la compatibilidad de incentivos en el diseño de algoritmos de IA y los marcos regulatorios es valioso, pero aborda una cuestión secundaria. Antes de considerar cómo garantizar que los sistemas de IA actúen de acuerdo con sus objetivos programados, debemos examinar los incentivos que influyen en quienes determinan cuáles deberían ser dichos objetivos. El capítulo se beneficiaría de explorar este nivel de complejidad, aunque solo fuera para descartar su relevancia, dado que las herramientas de gobernanza analógica existentes mantienen bajo control este problema de metaagencia.

Enfoques regulatorios: armonización global versus federalismo experimental

El capítulo presenta argumentos convincentes a favor de marcos de gobernanza coherentes, globales y unificados para abordar la naturaleza transfronteriza de los sistemas de IA y reducir el arbitraje regulatorio. Si bien este enfoque tiene mérito, especialmente para coordinar las respuestas a los riesgos sistémicos, puede subestimar tanto los desafíos prácticos de lograr un consenso regulatorio global como los beneficios potenciales de la diversidad regulatoria.

En primer lugar, la exigencia del capítulo de criterios uniformes para distinguir las acciones legítimas de las conductas manipuladoras en contextos de mercado ignora los mecanismos legales existentes que ya mitigan el arbitraje regulatorio transfronterizo. La «doctrina de los efectos» en la regulación del abuso de mercado, por ejemplo, permite a las jurisdicciones sancionar las conductas manipuladoras que afectan a sus mercados, independientemente de su origen. Si bien las capacidades superiores de la IA pueden complicar la aplicación de la ley, no necesariamente generan nuevos riesgos de arbitraje regulatorio en este ámbito específico.

En segundo lugar, el énfasis del capítulo en la armonización global no reconoce el valor de la experimentación regulatoria a nivel nacional o regional. Diversos enfoques regulatorios pueden funcionar como laboratorios para la innovación de políticas, lo que podría generar resultados regulatorios más efectivos a largo plazo en comparación con un enfoque coordinado y descendente. Al permitir que diferentes jurisdicciones prueben diversas respuestas regulatorias a los comportamientos del mercado impulsados por la IA, podemos obtener valiosa evidencia empírica sobre qué enfoques equilibran mejor la innovación y la mitigación de riesgos.

La cita en el capítulo del Informe Científico Internacional sobre la Seguridad de la IA293 Avanzada como evidencia del progreso hacia marcos globales es alentadora. Sin embargo, se vería fortalecida por un análisis más matizado sobre cuándo es necesaria la armonización y cuándo la diversidad regulatoria podría ser más beneficiosa para el desarrollo del mercado y la innovación.

Un enfoque más equilibrado podría abogar por estándares globales mínimos en áreas con externalidades claras o riesgos sistémicos, y al mismo tiempo alentar la experimentación en dominios donde las consecuencias siguen siendo localizadas o donde los enfoques regulatorios óptimos son inciertos.

La evolución de las asimetrías de información: adaptación y eficiencia del mercado

El análisis del capítulo sobre cómo la IA y el big data transforman las asimetrías de información en los mercados públicos destaca acertadamente que el big data proporciona a los inversores internos nuevas fuentes de información relevante no pública, mientras que los datos alternativos reducen simultáneamente las asimetrías de información entre inversores internos y externos. Sin embargo, la presentación en el capítulo de estos desarrollos principalmente como amenazas a la liquidez del mercado puede resultar excesivamente pesimista.

Las asimetrías de información no son simplemente imperfecciones del mercado que deben eliminarse, sino impulsores fundamentales de la actividad comercial y la eficiencia informativa. Los operadores buscan constantemente información sin precio, y sus acciones incorporan esta información a los precios, lo que beneficia la participación en el mercado y la liquidez a lo largo del tiempo. La preocupación del capítulo sobre que las nuevas formas de asimetría de información puedan perjudicar la liquidez no comprende plenamente esta perspectiva dinámica.

Si bien el análisis de datos alternativos impulsado por IA podría generar inicialmente disparidades entre los participantes del mercado, estas disparidades incentivan la innovación y la adaptación. El capítulo menciona brevemente, pero no explora a fondo, cómo podrían evolucionar los mercados en respuesta a las estrategias de negociación impulsadas por IA, de forma similar a cómo se adaptaron a la negociación de alta frecuencia mediante el desarrollo de dark pools y sistemas inteligentes de enrutamiento de órdenes.²⁹⁴ Esta capacidad de adaptación sugiere que las asimetrías iniciales podrían mitigarse con el tiempo a medida que más participantes desarrollen las capacidades necesarias o evolucionen los mecanismos del mercado.

La redefinición de la información privilegiada y la integridad del mercado

Una de las contribuciones más valiosas del capítulo es su exploración de cómo la IA redefine los límites entre la información interna y externa. Los marcos tradicionales que

Distinguir entre información pública y no pública se vuelve cada vez más inadecuado cuando la IA puede extraer información no obvia de datos públicos o cuando fuentes de datos alternativas difuminan la línea entre la investigación legítima y las ventajas injustas de la información.

²⁹³ Bengio y otros (2025).

²⁹⁴ O'Hara (2015).

El capítulo identifica eficazmente cómo la IA amplifica el procesamiento de información pública, lo que conduce a lo que denomina "asimetría de información pública", donde las capacidades tecnológicas, más que el acceso a información privilegiada, determinan las ventajas comerciales.

Este cambio tiene profundas implicaciones para la vigilancia y regulación del mercado, que el capítulo comienza a abordar a través de su discusión sobre la redefinición del acceso igualitario en un mercado impulsado por la IA y el establecimiento de principios para el uso justo de datos alternativos.

Sin embargo, el capítulo podría reconocer de forma más explícita que no todas las asimetrías de información justifican la intervención regulatoria. La principal preocupación no debería ser la asimetría de información en sí, sino la negociación informada dominada por información privilegiada. Esto se debe a que, cuando se permite la negociación con información privilegiada, los operadores profesionalmente informados pueden perder sistemáticamente frente a ellos, lo que puede reducir la eficiencia del mercado, ya que los operadores con información privilegiada pueden ser peores interpretando los efectos de los eventos en los precios a nivel macro, pueden abstenerse de negociar ante malas noticias, dado el impacto negativo que esto puede tener en su seguridad laboral, y también podrían ser irracionalmente optimistas al interpretar nueva información.²⁹⁵ Sería útil una tipología más granular de las ventajas de la información, que distinga entre aquellas que mejoran principalmente la eficiencia del mercado y aquellas que principalmente permiten la extracción de rentas o socavan la integridad del mercado.

Efectos de retroalimentación y reflexividad en los mercados impulsados por la IA

El capítulo aborda, aunque no desarrolla a fondo, las implicaciones de los efectos de retroalimentación, donde la percepción del mercado (ahora impulsada por la IA) influye en las decisiones gerenciales. Esta relación reflexiva entre las señales del mercado y el comportamiento corporativo adquiere nuevas dimensiones en un entorno dominado por la IA, donde los algoritmos de ambas partes pueden interactuar de forma impredecible.

Por ejemplo, si los directivos corporativos saben que los sistemas de IA analizan sus divulgaciones en busca de opiniones y palabras clave específicas, podrían modificar estratégicamente su lenguaje para manipular estos sistemas. De igual manera, si los algoritmos de trading responden de forma predecible a ciertos patrones de noticias, esto podría incentivar la sincronización estratégica o el enfoque de los anuncios corporativos. El capítulo reconoce estas dinámicas, pero podría explorar con mayor profundidad cómo podrían transformar tanto los entornos de información de mercado como las estrategias de divulgación corporativa.

Conclusión: Hacia una comprensión dinámica de la IA en las finanzas

El capítulo ofrece un análisis exhaustivo de cómo la IA transforma los entornos de gobernanza corporativa e información de mercado. Sin embargo, su principal limitación es la insuficiente atención a la naturaleza dinámica y evolutiva de estas transformaciones. Los mercados y las instituciones se adaptan a las disrupciones tecnológicas, a menudo de maneras que mitigan las preocupaciones iniciales y, al mismo tiempo, plantean nuevos desafíos.

²⁹⁵ Goshen y Parchomovsky (2005).

Una perspectiva más dinámica reconocería que las asimetrías iniciales creadas por la IA y los datos alternativos podrían evolucionar a medida que los participantes del mercado desarrollan contraestrategias, las regulaciones se adaptan y las tecnologías se vuelven más accesibles. El caso de la evolución del trading de alta frecuencia, de una fuerza disruptiva a una parte más integrada de la creación de mercado, ofrece un precedente valioso que podría fundamentar nuestras expectativas sobre el impacto a largo plazo de la IA.

Referencias

Abdul Jabbar, M., O. Wibisono, A. Widjanarti y A. Zulen (2022), "Aprendizaje automático para medir la credibilidad y la comunicación de las políticas de los bancos centrales a partir de las noticias", Boletín IFC 59.

Abis, S. (2022), "Hombre vs. Máquina: Gestión Cuantitativa y Discrecional del Capital", disponible en SSRN.

Abis, S. y L. Veldkamp (2024), "La economía cambiante de la producción de conocimiento", The Review of Financial Studies 37(1): 89–118.

Accornero, M. y G. Boscariol (2021), "Aprendizaje automático para la detección de anomalías en conjuntos de datos con variables categóricas y distribuciones sesgadas", Boletín IFC 57.

Acemoglu, D., D. Autor, J. Hazell y P. Restrepo (2022), "Inteligencia artificial y empleos: evidencia de las vacantes en línea", Journal of Labor Economics 40: 293-340.

AFM – Autoridad Holandesa de los Mercados Financieros (2023), "Aprendizaje automático en el trading algorítmico", 3 de marzo.

Aghion, P. y P. Bolton (1992), "Un enfoque de contratos incompletos para la contratación financiera", The Review of Economic Studies 59(3): 473–494.

Agrawal A., JS Gans y A. Goldfarb (2017), "Máquinas de predicción, juicio y complejidad", en A. Agrawal, J. Gans y A. Goldfarb (eds), The Economics of Artificial Intelligence, University of Chicago Press.

Agrawal, A., J. Gans y A. Goldfarb (2018), Máquinas de predicción: la economía simple de la inteligencia artificial, Harvard Business Press.

Ahnert, T., S. Doerr, N. Pierri e Y. Timmer (2024), "Tecnología de la información en la banca y el emprendimiento", Management Science, próximamente.

Akerlof, GA (1970), "El mercado de los 'limones': incertidumbre de calidad y mecanismo del mercado", Quarterly Journal of Economics 84: 488–500.

Ala-Pietila, P., Y. Bonnet, U. Bergmann et al. (2020), "La lista de evaluación para una inteligencia artificial confiable (ALTAI)", Comisión Europea.

Aldasoro, I., O. Armantier, S. Doerr, L. Gambacorta y T. Oliviero (2024a), "Evidencia de encuestas sobre la generación de IA y los hogares: perspectivas laborales en medio de preocupaciones sobre la confianza", Boletín BIS 86.

Aldasoro, I., S. Doerr, L. Gambacorta, S. Notra, T. Oliviero y D. Whyte (2024b), "Inteligencia artificial generativa y ciberseguridad en la banca central", Documento de debate del CEPR 19244.

Aldasoro, I., S. Doerr, L. Gambacorta y D. Rees (2024c), "El impacto de la inteligencia artificial en la producción y la inflación", Documento de debate del CEPR 19604.

Aldasoro, I., L. Gambacorta, A. Korinek, V. Shreeti y M. Stein (2024d), "Sistema financiero inteligente: cómo la IA está transformando las finanzas", Documento de debate del CEPR 19181.

Aldasoro, I., S. Doerr, L. Gambacorta, G. Gelos y D. Rees (2024e), " Inteligencia artificial, mercados laborales e inflación", SUERF Policy Brief 923.

Altman, S. (2024), "La era de la inteligencia", 23 de septiembre (<https://ia.samaltman.com>).

Altman, S (2025), "Reflexiones", 6 de enero (<https://blog.samaltman.com/reflections>).

Altmeyer P., AM Demetriou, A. Bartlett y CCS Liem (2024), "Dejen de hacer afirmaciones no científicas sobre el rendimiento de la AGI", artículo presentado en la 41.ª ICML, Viena.

Amodei, D. (2024), "Máquinas de gracia amorosa", octubre (<https://darioamodei.com/máquinas-de-gracia-amorosa>).

Anthropic (2024), "Uso de la computadora", 22 de octubre (<https://www.anthropic.com/news/3-5-modelos-y-uso-de-computadoras>).

Aquilina, M., E. Budish y P. O'Neill (2022), "Cuantificación de la 'carrera armamentista' del comercio de alta frecuencia", *The Quarterly Journal of Economics* 137: 493–564.

Aramonte, S., W. Huang y A. Schrimpf (2021), "Riesgos de DeFi y la ilusión de la descentralización", *BIS Quarterly Review*, diciembre.

Araujo, D., G. Bruno, J. Marcucci, R. Schmidt y B. Tissot (2022), "Aplicaciones de aprendizaje automático en la banca central: una descripción general", *Boletín IFC* 57.

Araujo, D., G. Bruno, J. Marcucci, R. Schmidt y B. Tissot (2023), "Ciencia de datos en la banca central: aplicaciones y herramientas", *Boletín IFC* 59.

Araujo, D., S. Doerr, L. Gambacorta y B. Tissot (2024), "Inteligencia artificial en la banca central", *Boletín del BIS* 2024.

Armantier O., S. Doerr, J. Frost, A. Fuster y K. Shue (2021), "¿En quién confían los consumidores sus datos? Evidencia de encuestas en EE. UU.", *Boletín BIS* 42.

Armas, A., M. Luna y C. Montoro (2024), "La naturaleza cambiante del sistema financiero: implicaciones para la resiliencia y el crecimiento a largo plazo en las economías de mercado emergentes: la experiencia peruana", *BIS Papers* No. 148, Banco de Pagos Internacionales.

Armour, J, R. Parnham y M. Sato, M. (2020), "Abogacía aumentada", documento de trabajo.

Asker, J., C. Fershtman y A. Pakes (2024), "El impacto del diseño de inteligencia artificial en los precios", *Journal of Economics and Management Strategy* 33: 276–304.

Assad, S., R. Clark, D. Ershov y L. Xu, (2024), "Precios algorítmicos y competencia: evidencia empírica del mercado minorista alemán de gasolina", *Journal of Political Economy* 132: 723-771.

- Avdjiev, S., B. Bogdanova, P. Bolton, W. Jiang y A. Kartasheva (2020), "Emisión de CoCo y fragilidad bancaria", *Journal of Financial Economics* 138(3): 593–613.
- Bai, J., T. Phillipon y A. Savov (2016), "¿Se han vuelto más informativos los mercados financieros?", *Journal of Financial Economics* 122: 625-654.
- Baik, B., AG Kim, DS Kim y Y. Sangwon (2024), "Calidad de la presentación vocal en las conferencias telefónicas sobre ganancias", *Journal of Accounting and Economics* (próximamente).
- Balch, T., D. Byrd, W. Jiang y B Yang (2025), "Aprender a portarse mal sin que se lo enseñen: manipulación del mercado mediante IA con aprendizaje de refuerzo", documento de trabajo, Universidad Emory.
- Baldauf, M. y J. Mollner (2020), "Negociación de alta frecuencia y desempeño del mercado", *Journal of Finance* 75: 1495-1526.
- Barberis, N. y L. Jin (2023), "Aprendizaje basado en modelos y sin modelos como impulsores conjuntos del comportamiento de los inversores", Documento de trabajo NBER 31081.
- Barbopoulos, L., R. Dai, T. Putnins y A. Saunders (2023), "Eficiencia del mercado cuando las máquinas acceden a la información", disponible en SSRN.
- Baron, M., J. Brogaard, B. Hagströmer y A. Kirilenko (2019), "Riesgo y rendimiento en el trading de alta frecuencia", *Journal of Financial and Quantitative Analysis* 54: 993-1024.
- Bartov, E., L. Faurel y PS Mohanram (2018), "¿Puede Twitter ayudar a predecir las ganancias y el rendimiento de las acciones a nivel de empresa?", *The Accounting Review* 93: 25–57
- Bassett, WF y RL Lumsdaine (2001), "Límites de probabilidad: ¿Son las evaluaciones subjetivas lo suficientemente precisas?", *Journal of Human Resources* 36(2): 327-363.
- Beason, T. y S. Wahal (2020), "La anatomía de los algoritmos de trading", disponible en SSRN.
- Beaumont, P., H. Tang y E. Vansteenberghe (2024), "Efectos colaterales: el papel de las fintech en los préstamos a las pequeñas empresas", *Débats économiques et financiers* 42.
- Beaver Finance (2022), "Lección de seguridad DeFi 7: Manipulación del oráculo de precios", Medium, 13 de enero.
- Beck, T., L. Gambacorta, Y. Huang, Z. Li y H. Qiu (2022), "Big techs, pagos con código QR e inclusión financiera", Documento de trabajo del BIS 1011.
- Beck, T., T. Peltonen, E. Perotti, A. Sánchez Serrano y J. Suarez (2023), Crédito corporativo y apalancamiento en la UE: evolución reciente, principales impulsores e implicaciones para la estabilidad financiera, Informe del Comité Científico Asesor de la Junta Europea de Riesgo Sistémico 14.
- Beerman, K., J. Prenio y R. Zamil (2021), "Herramientas Suptech para la supervisión prudencial y su uso durante la pandemia", FSI Insights on Policy Implementation 37.

Begenau, J., M. Farboodi y L. Veldkamp (2018), "Big data en finanzas y el crecimiento de las grandes empresas", *Journal of Monetary Economics* 97: 71–87.

Bell S., B. Gadanecz, L. Gambacorta, F. Perez-Cruz y V. Shreeti (2025), "Inteligencia artificial y capital humano: desafíos para los bancos centrales", *BIS Bulletin* 100.

Benamar H., T. Foucault y C. Vega, (2021), "Demanda de información, incertidumbre macroeconómica y respuesta de los bonos del Tesoro estadounidense a las noticias", *Review of Financial Studies* 34: 3403-3455.

Bengio, Y., S. Mindermann, D. Privitera et al. (2025), "Informe internacional de seguridad de la IA", preimpresión de arXiv, arXiv:2501.17805.

Berg, T., V. Burg, A. Gombović y M. Puri (2020), "Sobre el auge de las fintechs: calificación crediticia mediante huellas digitales", *Revista de Estudios Financieros* 33: 2845-97.

Berg, T., V. Burg, J. Keil y M. Puri (2025), "La economía de 'Comprar ahora, pagar después': la perspectiva de un comerciante", *Journal of Financial Economics*, de próxima publicación.

Berger, AN y GF Udell (1990), "Garantía, calidad del préstamo y riesgo bancario", *Journal of Monetary Economics* 25: 21–42.

Berger, AN y GF Udell (1995), "Préstamos relacionales y líneas de crédito en las finanzas de pequeñas empresas", *Journal of Business* 68(3): 351–381.

Biais, B., T. Foucault, T. y S. Moinas (2015), "Equilibrium Fast Trading", *Journal of Financial Economics* 116: 292-313.

Biglaiser G., J. Cremer y A. Mantovani (2024), "La economía de la nube", Documento de trabajo TSE 1520.

BPI – Banco de Pagos Internacionales (2019), *Big Techs en finanzas: oportunidades y riesgos*, Informe económico anual del BPI, junio.

BPI (2023), *Plan para el futuro sistema monetario: mejorar lo antiguo y posibilitar lo nuevo*, Informe Económico Anual del BPI, junio.

BPI (2024), *Inteligencia artificial y economía: implicaciones para los bancos centrales*, Informe Económico Anual del BPI, junio.

BIS Innovation Hub (2023), "Proyecto Aurora: el poder de los datos, la tecnología y la colaboración para combatir el lavado de dinero a través de instituciones y fronteras", mayo.

Björkegren, D., JE Blumenstock y S. Knight (2020), "Aprendizaje automático a prueba de manipulación", preimpresión de arXiv arXiv:2004.03865.

Blankenburg J. y O. Röhe (2024), "Plataforma TIA: Análisis de la implementación de reformas estructurales", *Foro de Liderazgo en Tecnología de Banca Central*, 4-5 de diciembre.

Blankespoor, E., BP Miller y HD White (2014) "Evidencia inicial sobre el impacto en el mercado del mandato XBRL", *Review of Accounting Studies* 19: 1468–1503.

Blankespoor, E., E. deHaan e I. Marinovic (2020), "Costos de procesamiento de divulgación, elección de información de los inversores y resultados del mercado de valores: una revisión", *Journal of Accounting and Economics* 70: 1–46.

Bogousslavsky, N., V. Fos y D. Murayev (2024), "Intensidad comercial informada", *Journal of Finance* 79: 903-948.

Bohren, JA (2016), "Registro informativo con especificación incorrecta del modelo", *Journal of Economic Theory* 163: 222-247.

Boissay, F., T. Ehlers, L. Gambacorta y HS Shin (2021), "Big techs en finanzas: sobre el nuevo nexo entre privacidad de datos y competencia", en R. Rau, R. Wardrop y L.

Zingales (eds), *El manual Palgrave de finanzas internacionales*, Springer International Publishing.

Bolandnazar, M., RJ Jackson, W. Jiang y J. Mitts (2020), "Negociar contra la expiración aleatoria de información privada: un experimento natural", *Journal of Finance* 75: 5–44.

Bolton, P., X. Freixas, L. Gambacorta y PE Mistrulli (2016), "Préstamos relacionales y transaccionales en una crisis", *Review of Financial Studies* 29(10): 2643–2676.

Bond, P., A. Edmans e I. Goldstein (2012), "Los efectos reales de los mercados financieros", *Annual Review of Economics* 1: 339-36.

Bonelli, M. (2024), "Data-Driven Investors", documento de trabajo, London Business School.

Bonelli, M. y T. Foucault (2024), "¿El big data devalúa la experiencia tradicional? ¿Evidencia de fondos activos?", documento de trabajo, HEC París.

Bonfim, D., C. Custódio y C. Raposo (2023), "Apoyo a las pequeñas empresas durante recesiones y recuperaciones", *Journal of Financial Economics* 147: 658–688.

Bonfim, D., A. Matyunina, R. De Haas y S. Ongena (2025), "Especialización bancaria en préstamos a nuevas empresas", mimeo.

Bostrom, N. (2015), *Superinteligencia: caminos, peligros, estrategias*, Oxford University Press.

Botti, N., F. Haberkorn y S. Khan (2025), "Eficacia de las herramientas AI RAG para tareas complejas de extracción de información y anotación de datos en documentos bancarios", 4º Taller de la IFC y el Banco de Italia sobre ciencia de datos en la banca central, 18-20 de febrero.

Bourveau, T., J. Brendel y J. Schoenfeld (2023), "Garantía de finanzas descentralizadas (DeFi): evidencia temprana", *Review of Accounting Studies*, próximamente.

Brandts, J., AE Giritligil y RA Weber (2015), "Un estudio experimental del sesgo de persuasión y la influencia social", *European Economic Review* 80: 214-229.

Brav, A., W. Jiang, F. Partnoy y R. Thomas (2008), "Activismo de los fondos de cobertura, gobierno corporativo y desempeño de las empresas", *Journal of Finance* 63: 1729–1775.

Breckenfelder, J. (2024), "Competencia entre traders de alta frecuencia y calidad del mercado", *Journal of Economic Dynamics and Control* 166: 2-22.

Brogaard, J. y C. Garriott (2019), "Competencia en trading de alta frecuencia", *Journal of Financial and Quantitative Analysis* 54: 1469-1497.

Brogaard, J. y A. Zareei (2023), "Aprendizaje automático y el mercado de valores", *Journal of Financial and Quantitative Analysis* 58: 1431-1472.

Brogaard, J., T. Hendershott y R. Riordan (2017), "Negociación de alta frecuencia y la prohibición de ventas en corto de 2008", *Journal of Financial Economics* 124: 22-42.

Brown, ZY y A. MacKay (2023), "Competencia en algoritmos de precios", *American Economic Journal: Microeconomics* 15: 109–56.

Browning, J. y Y. LeCun (2022), "IA y los límites del lenguaje", *Noema*, 23 de agosto.

Brynjolfsson, E. y K. McElheran (2019), "Datos en acción: toma de decisiones basada en datos y análisis predictivo en la industria manufacturera estadounidense", *Rotman School of Management*, documento de trabajo 3422397.

Brynjolfsson, E., D. Li y L. Raymond (2023), "IA generativa en el trabajo", *Documento de trabajo NBER* 31161.

Bryzgalova, S., M. Pelger y J. Zhu (2020), "El bosque a través de los árboles: construcción de secciones transversales de retornos de acciones", disponible en SSRN.

Buchak, G., G. Matvos, T. Piskorski y A. Seru (2018), "Fintech, arbitraje regulatorio y el auge de los bancos en la sombra", *Journal of Financial Economics* 130(3): 453-483.

Buchak, G., G. Matvos, T. Piskorski y A. Seru (2022), "¿Por qué es tan difícil la intermediación inmobiliaria? Evidencia de compradores iBuyers", *Documento de Trabajo NBER* 28252.

Buckmann, M., G. Potjagailo y P. Schnattinger (2023), "Diseción de la inflación de servicios del Reino Unido a través de una curva de Phillips de red neuronal", *Banco de Inglaterra, Bank Underground*, 10 de julio.

Budish, E., P. Cramton y J. Shim (2015), "La carrera armamentista del comercio de alta frecuencia: subastas frecuentes por lotes como respuesta al diseño del mercado", *The Quarterly Journal of Economics* 130: 1547–1621.

Bushman, RM y AJ Smith (2001), "Información contable financiera y gobierno corporativo", *Journal of Accounting and Economics* 32: 237–333.

Byrd, D. (2022), "Aprender a no engañar", en *Actas de la Tercera Conferencia Internacional de la ACM sobre IA en Finanzas*, págs. 139-147.

- Cabiddu, F., L. Moi, G. Patriotta y D. Allen (2022), "¿Por qué los usuarios confían en los algoritmos? Una revisión y conceptualización de la confianza y la confianza a lo largo del tiempo", *European Management Journal* 40: 685-706.
- Cagala, T., J. Hees, D. Herurkar, M. Meier, N.-T. Nguyen, T. Sattarov, K. Troutman y P. Weber (2021), "Detección de valores atípicos no supervisados en estadísticas oficiales", *Boletín IFC* 57.
- Calvano, E., G. Calzolari, V. Denicolo y S. Pastorello (2020a), "Inteligencia artificial, precios algorítmicos y colusión", *American Economic Review* 110(10): 3267–3297.
- Calvano, E., G. Calzolari, V. Denicolò, J. Harrington y S. Pastorello (2020b), "Protegiendo a los consumidores de precios colusorios debido a la IA", *Science* 370: 1040-1042.
- Campello, M., LW Cong y L. Zhou (2024), "Alphamanager: Un enfoque de control robusto basado en datos para las finanzas corporativas", documento de trabajo, Universidad de Florida.
- Cao, K. y H. You (2024), "Análisis fundamental mediante aprendizaje automático", *Financial Analysts Journal* 80: 74-98.
- Cao, J., J. Chen, J. Hull, Z. Poulos (2020), "Cobertura profunda de derivados mediante aprendizaje por refuerzo", documento de trabajo, Universidad de Toronto.
- Cao, S., W. Jiang, B. Yang y AL Zhang (2023), "Cómo hablar cuando una máquina está escuchando: divulgación corporativa en la era de la IA", *The Review of Financial Studies* 36(9): 3603–3642.
- Cao, S., W. Jiang, J. Wang y B. Yang (2024), "Del hombre contra la máquina al hombre + máquina: El arte y la IA de los análisis bursátiles", *Journal of Financial Economics* 160.
- Cao, S., Y. Cheng, M. Wang, Y. Xia y B. Yang (2025), "La brecha entre la información visual y la IA: evidencia de presentaciones ejecutivas corporativas", disponible en SSRN.
- Carletti, E. (2004), "La estructura de las relaciones bancarias, el monitoreo endógeno y las tasas de préstamo", *Journal of Financial Intermediation* 13(1): 58–86.
- Carletti, E., A. Fatas, S. Claessens y X. Vives (2020), *El modelo de negocio bancario en el mundo post-Covid 19*, The Future of Banking 2, CEPR Press.
- Cartea, A., P. Chang y G. Garcia-Arenas (2023), "Spoofing and Manipulating Order Books with Learning Algorithms", documento de trabajo, Oxford-Man Institute of Quantitative Finance.
- Cespa, G. y T. Foucault (2014), "Contagio de iliquidez y caídas de liquidez", *The Review of Financial Studies* 27: 1615–1660.
- Cespa, G. y X. Vives (2025), "Opacidad y fragilidad del mercado: Por qué la liquidez se evapora cuando más se necesita", documento de trabajo.
- Chabakauri, G., V. Fos y W. Jiang (2025), "Negociar antes de la llegada de los bárbaros a la puerta: Comercio de información privilegiada con información no privilegiada", *The Review of Finance*, de próxima publicación.

Chainalysis (2023), "Los ataques de manipulación de oráculos están aumentando, lo que genera una preocupación única para DeFi", blog, 7 de marzo.

Chan, A., C. Ezell, M. Kaufmann et al. (2024), "Visibilidad en agentes de IA", preimpresión de arXiv arXiv:2401.13138.

Charpentier, A., E. Romuald y C. Remlinger (2020), "Aprendizaje de refuerzo en economía y finanzas", documento de trabajo, ArXiv.

Chen, Q., I. Goldstein y W. Jiang (2007), "Información de precios y sensibilidad de la inversión al precio de las acciones", *The Review of Financial Studies* 20(3): 619–650.

Chen, H., P. De, Y. Hu y B.-H. Hwang (2014), "Sabiduría de las multitudes: El valor de las opiniones sobre acciones transmitidas a través de las redes sociales", *The Review of Financial Studies* 27(5): 1367–1403.

Chen, Y., B. Kelly y D. Xiu (2022b), "Retornos esperados y modelos de lenguaje grandes", disponible en SSRN.

Chen, L., M. Pelger y J. Zhu (2023a), "Aprendizaje profundo en la fijación de precios de activos", *Management Science* 70: 714-750.

Chen, MA, SS Hu, J. Wang y Q. Wu (2023b), "¿Puede la tecnología blockchain ayudar a superar la incompletitud contractual? Evidencia de las leyes estatales", *Management Science* 69(11): 6540–6567.

Chi, F., B.-H. Hwang y Y. Zheng (2023), "El uso y la utilidad del big data en las finanzas: evidencia de los analistas financieros", *Management Science*, próximamente.

Ministerio de Tecnología de China (2019), Principios de gobernanza para una nueva generación de inteligencia artificial: Desarrollar una inteligencia artificial responsable.

Chinco, A., A. Clark-Joseph y M. Ye (2019), "Señales dispersas en la sección transversal de retornos", *Journal of Finance* 74: 449 – 492.

Christian, B. (2020), *El problema de la alineación: aprendizaje automático y valores humanos*, WW Norton & Company.

Chugunova, M. y WJ Luhan (2024), "Gobernados por robots: preferencia por los tomadores de decisiones algorítmicos y percepciones de sus elecciones", *Public Choice* 202: 1-24.

Citi GPS (2024), *IA en finanzas: bots, bancos y más allá*, junio.

Citi GPS (2025), *Agentic AI: Finance & the "Hazlo por mí" Economy*, enero.

Claessens, S. (2009), "Competencia en el sector financiero: panorama general de las políticas de competencia", *The World Bank Research Observer* 24(1): 83–118.

CMA – Autoridad de Competencia y Mercados (2024), "Modelos básicos de IA: documento actualizado", 11 de abril.

Coase, RH (1937), "La naturaleza de la empresa", en Williamson y SG Winter (eds) (1993), *La naturaleza de la empresa: orígenes, evolución y desarrollo*.

Cohen, L., C. Malloy y Q. Nguyen (2020), "Precios perezosos", *The Journal of Finance* 75: 1371-1415.

Coleman, B., K. Merkley y J. Pacelli (2022), "Humano versus máquina: una comparación de las recomendaciones de inversión de los analistas robot y los analistas de investigación tradicionales", *The Accounting Review* 97: 221-244.

Colliard, JE, T. Foucault y S. Lovo (2023), "Precios algorítmicos y liquidez en los mercados de valores", disponible en SSRN.

Cong, LW y Z. He (2019), "Disrupción de blockchain y contratos inteligentes", *The Review of Financial Studies* 32(5): 1754-1797.

Cong, LW, Z. He y J. Li (2021), "Minería descentralizada en pools centralizados", *The Review of Financial Studies* 34(3): 1191-1235.

Cong, L., Ke, T., J. Wang y Y. Zhang (2022), "AlphaPortfolio: construcción directa a través del aprendizaje de refuerzo profundo y la IA interpretable", disponible en SSRN.

Cong, LW, D. Rabetti, CC Wang y Y. Yan (2023), "Gobernanza centralizada en organizaciones descentralizadas", disponible en SSRN.

Costello, A., A. Down y M. Metha (2020), "Máquina + hombre: un experimento de campo sobre el papel de la discreción en la ampliación de los modelos de préstamos basados en IA", *Journal of Accounting and Economics* 70: 1013-1060.

Coughlan, J. y AG Orlov (2023), "Negociación de alta frecuencia y calidad del mercado: evidencia de datos de futuros a nivel de cuenta", *Journal of Futures Markets* 43(8): 1126-1160.

Crisanto, JC, CB Leuterio, J. Prenio y J. Yong (2024), "Regulación de la IA en el sector financiero: desarrollos recientes y principales desafíos", *FSI Insights* 63.

D'Acunto, F., N. Prabhala y A. Rossi (2019), "Las promesas y las trampas del robo-advising", *Review of Financial Studies* 32: 1984-2020.

da Silva, T. y D. Thesmar (2024), "Ruido en las expectativas: evidencia de los pronósticos de los analistas", *The Review of Financial Studies* 37: 1494-1537.

De Fiore, F., G. Cornelli, L. Gambacorta y C. Manea (2024), "Big tech, Financial intermediation and the macroeconomy", *Boston FED Discussion Paper*, 12 de noviembre.

De Roure, C., L. Pelizzon y P. Tasca (2016), "¿Cómo encajan los préstamos P2P en el mercado de crédito al consumo?", *Documento de debate del Deutsche Bundesbank* 30.

Danielsson, J., R. Macrae, A. Uthemann (2022), "Inteligencia artificial y riesgos sistémicos", *Journal of Banking and Finance* 140: 106290.

Dass, N. y M. Massa (2011), "El impacto de una fuerte relación banco-empresa en la empresa prestataria", *Review of Financial Studies* 24(4): 1204–1260.

DeepMind (2024), "Proyecto Mariner" (<https://deepmind.google/technologies/project-mariner/>).

186

Degryse, H. y S. Ongena (2005), "Distancia, relaciones crediticias y competencia", *Journal of Finance* 60: 231–266.

DeMarzo, PM, D. Vayanos y J. Zwiebel (2003), "Sesgo de persuasión, influencia social y opiniones unidimensionales", *The Quarterly Journal of Economics* 118(3): 909-968.

Denes, J., A. Lestrade y L. Richardet (2021), "Uso de datos de Twitter para medir la percepción de la inflación", *IFC Bulletin* 57.

Dessaint, O., T. Foucault y L. Frésard (2024), "¿Mejoran los datos alternativos la previsión financiera? El efecto horizonte", *Journal of Finance* 79: 2237-2287.

Dessaint, O., T. Foucault y L. Frésard (2025), "El horizonte de la información de los inversores y la inversión corporativa", disponible en SSRN.

Diamond, DW y RE Verrecchia (1991), "Divulgación, liquidez y costo del capital", *Journal of Finance* 46: 1325–1359.

Dietvorst, BJ, JP Simmons y C. Massey (2015), "Aversión a los algoritmos: las personas evitan erróneamente los algoritmos después de verlos equivocarse", *Journal of Experimental Psychology: General* 144(1): 114-126.

Dietvorst, BJ, JP Simmons y C. Massey (2018), "Superar la aversión a los algoritmos: las personas usarán algoritmos imperfectos si pueden modificarlos (aunque sea ligeramente)", *Management Science* 64(3): 1155-1170.

Doerr, S. (2020), "Auge inmobiliario, reasignación y productividad", Documento de trabajo del BPI 904.

Dong, GN (2024), "¿Puede la IA reemplazar a los analistas bursátiles? Evidencia de estados financieros con aprendizaje profundo", disponible en SSRN.

Dou, WW, I. Goldstein y Y. Ji (2023), "Negocio impulsado por IA, colusión algorítmica y eficiencia de precios", disponible en SSRN.

Du, S., K. Guo, F. Haberkorn, A. Kessler, I. Kitschelt, SJ Lee, A. Monken, D. Saez, K.

Shipman y S. Thakur (2024), "¿Importan las anécdotas? Explorando el Libro Beige a través del análisis textual de 1970 a 2023", *Boletín del IFC*, próxima publicación.

Duffie, D., T. Foucault, L. Veldkamp y X. Vives (2022), *Tecnología y finanzas, El futuro de la banca* 4, CEPR Press.

Dugast, J. y T. Foucault (2018), "Abundancia de datos e información sobre los precios de los activos", *Journal of Financial Economics* 130(2): 367–391.

- Dugast, J. y T. Foucault (2025), "Minería de datos de equilibrio y abundancia de datos", *Journal of Finance* 80: 211-258.
- BCE – Banco Central Europeo (2023), "Suptech: prosperando en la era digital", *Supervision Newsletter*, 15 de noviembre.
- Easley, D., M. López de Prado, M. O'Hara y Z. Zhang (2021), "Microestructura en la era de las máquinas", *The Review of Financial Studies* 34: 3316–3363.
- Edmans, A., S. Jayaraman y J. Schneemeier (2017), "La fuente de información en precios y sensibilidad al precio de la inversión", *Journal of Financial Economics* 126: 74-96.
- Eisfeldt, AL y G. Schubert (2024), "AI and Finance", NBER Working Paper 33076.
- Enke, B. y F. Zimmermann (2019), "Descuido de la correlación en la formación de creencias", *Review of Economic Studies* 86: 313-332.
- Enriques, L. y D. Zetsche (2020), "Tecnologías corporativas y la falacia del nirvana tecnológico", 72 *Hastings Law Journal*: 55-98.
- ESMA – Autoridad Europea de Valores y Mercados (2020) "Informe de revisión de MiFID II/MiFIR sobre negociación algorítmica", Documento de consulta.
- Unión Europea (2024), "Reglamento del Parlamento Europeo y del Consejo por el que se establecen normas armonizadas sobre la inteligencia artificial (Ley de Inteligencia Artificial) y se modifican determinados actos legislativos de la Unión".
- Ewertz, J., C. Knickrehm, M. Nienhaus y D. Reichmann (2024), "Escuche atentamente: medición del tono vocal en las divulgaciones corporativas", disponible en SSRN.
- Ezrachi, A. y M. Stuche (2017), "Inteligencia artificial y colusión: cuando las computadoras inhiben la competencia", *University of Illinois Law Review* 5: 1776-1808.
- Farboodi, M. y L. Veldkamp (2020), "Crecimiento a largo plazo de la tecnología de datos financieros", *American Economic Review* 110: 2485-2523.
- Farboodi, M. y L. Veldkamp (2023), "Datos y mercados", *Revista Anual de Economía* 15: 23–40.
- Farboodi, M., R. Mihet, T. Philippon y L. Veldkamp (2019), "Big data y dinámica de empresas", *AEA Papers and Proceedings* 109: 38-42.
- Farboodi, M., A. Matray, L. Veldkamp y V. Venkateswaran, (2022), "¿A dónde se fueron todos los datos?", *The Review of Financial Studies* 35: 3101–3138.
- Farboodi, M., D. Singal, L. Veldkamp y V. Venkateswaran (2024), "Valoración de datos financieros", *The Review of Financial Studies*, próximamente.
- Feyen, E., J. Frost, L. Gambacorta, H. Natarajan y M. Saal (2021), "Un triángulo de políticas para las grandes tecnológicas en las finanzas", *VoxEU.org*, octubre.

Foucault, T., R. Kozhan y W. Tham (2017), "Arbitraje tóxico" *Review of Financial Studies* 30: 1053-1094.

Foucault T., M. Pagano y A. Röell (2024), *Liquidez del mercado: teoría, evidencia y política*, Oxford University Press.

Frazzini, A., R. Israel, T. Moskowitz (2018), "Costos comerciales", disponible en SSRN.

Froot, K., N. Kang, G. Ozik y R. Sadka (2017), "¿Qué dicen las medidas de ventas corporativas en tiempo real sobre las sorpresas de ganancias y los retornos posteriores al anuncio?", *Journal of Financial Economics* 125(1): 143–162.

Frost, J., L. Gambacorta, Y. Huang, HS Shin y P. Zbinden (2019), "BigTech y la estructura cambiante de la intermediación financiera", *Economic Policy* 34(100): 761–799.

Fudenberg, D. y J. Tirole (1991), *Teoría de juegos*, MIT Press.

Fuster, A., M. Plosser, P. Schnabl y J. Vickery (2019), "El papel de la tecnología en los préstamos hipotecarios", *The Review of Financial Studies* 32(5): 1854–99.

Fuster, A., P. Goldsmith-Pinkham, T. Ramadorai y A. Walther (2022), "¿Predeciblemente desigual? Los efectos del aprendizaje automático en los mercados crediticios", *The Journal of Finance* 77(1): 5-47.

Gabaix, X., D. Laibson, G. Moloche y S. Weinberg (2006), "Adquisición costosa de información: análisis experimental de un modelo racional acotado", *American Economic Review* 96(4): 1043-1068.

Gambacorta, L. y V. Shreeti (2025), "La cadena de suministro de IA", BIS Paper 154.

Gambacorta, L., Y. Huang, Z. Li, H. Qiu y S. Chen (2023), "Datos vs. Garantías.", *Review of Finance* 27(2): 369–398.

Gambacorta, L., Y. Huang, H. Qiu y J. Wang (2024a), "¿Cómo afectan el aprendizaje automático y los datos no tradicionales a la calificación crediticia? Nueva evidencia de una empresa fintech china", *Journal of Financial Stability* 73: 101284.

Gambacorta, L., B. Kwon, T. Park, P. Patelli y S. Zhu (2024b), "CB-LMs: modelos de lenguaje para la banca central", BIS Working Papers 1215.

Gambacorta, L., H. Qiu, D. Rees y S. Shan (2024c), "IA generativa y productividad laboral: un experimento de campo sobre codificación", Documento de trabajo del BIS 1208.

Gambacorta, L., F. Sabatini y S. Schiaffi (2025), "Inteligencia artificial y préstamos relacionales", Documento de trabajo del Banco de Italia 1476.

Ganong, P. y P. Noel (2023), "¿Por qué los prestatarios incumplen con sus hipotecas?", *The Quarterly Journal of Economics* 138(2): 1001–1065.

Gans, J. (2024), "Poder de mercado en inteligencia artificial", mimeo.

- Gao, M. y J. Huang (2020), "Informar al mercado: El efecto de las tecnologías de la información modernas en la producción de información", *Review of Financial Studies* 33: 1367-1411.
- Gartner (2024), "Gartner afirma que los ingresos mundiales por servicios de nube pública IaaS crecieron un 16,2 % en 2023", 22 de julio.
- Georges, C. y J. Pereira (2021), "Estabilidad del mercado con agentes de aprendizaje automático", *Journal of Economic Dynamics and Control* 122: 104032.
- Ghosh, P., B. Vallee e Y. Zeng (2024), "Préstamos fintech y pagos sin efectivo", *The Journal of Finance*, próximamente.
- Glode, V., RC Green y R. Lowery (2012), "La experiencia financiera como carrera armamentista", *The Journal of Finance* 67: 1723-1759.
- Goldman Sachs (2018), "Liquidez, volatilidad, fragilidad", *Top of Mind* 68, 12 de junio.
- Goldstein, I. (2023), "La información en los mercados financieros y sus efectos reales", *Review of Finance* 27(1):1–32.
- Goldstein, I. y L. Yang (2015), "Diversidad de información y complementariedades en el comercio y la adquisición de información", *The Journal of Finance* 70: 1723-1765.
- Gopinath, G. (2024), "¿Amplificador de crisis? Cómo evitar que la IA empeore la próxima recesión económica", discurso pronunciado en la Cumbre Global de IA para el Bien, 30 de mayo.
- Goshen, Z. y G. Parchomovsky (2005), "El papel esencial de la regulación de valores", *Duke Law Journal* 55: 711-782.
- Gray, N. y D. Jones (2025), "Transformando el análisis de encuestas: herramientas para los bancos centrales", 4º Taller de la CFI y el Banco de Italia sobre Ciencia de Datos en la Banca Central, 18-20 de febrero.
- Green, C., R. Huang, Q. Wen y D. Zhiu (2019), "Reseñas de empleadores colaborativas y rentabilidad de las acciones", *Journal of Financial Economics* 134: 236-251.
- Greenwich Associates (2017), "Datos alternativos para alfa" (<https://www.greenwich.com/acciones/datos-alternativos-alfa>).
- Grennan, J. y R. Michaely (2021), "FinTechs y el mercado del análisis financiero", *Journal of Financial and Quantitative Analysis* 56: 1877-1907.
- Grossman, SJ y OD Hart (1986), "Los costos y beneficios de la propiedad: una teoría de integración vertical y lateral", *Journal of Political Economy* 94(4): 691–719.
- Gu, S., B. Kelly y D. Xiu (2020), "Precios empíricos de activos mediante aprendizaje automático", *The Review of Financial Studies* 33: 2223–2273
- Hacker, P. (2023), "Manipulación mediante algoritmos. Explorando el triángulo de las prácticas comerciales desleales, la protección de datos y el derecho a la privacidad", *European Law Journal* 29: 142–175.

Hafsi, H. y V. Vittori (2024), "Ejecución óptima con aprendizaje de refuerzo", <https://arxiv.org/abs/2411.06389>.

Hambly, BM, R. Xu y H. Yang (2023), "Avances recientes en el aprendizaje de refuerzo en finanzas", documento de trabajo, Universidad de Oxford.

Han, Z. (2024), "¿La adopción de IA en los equipos de fusiones y adquisiciones mejora el rendimiento de las transacciones?", documento de trabajo, Universidad Emory.

Hart, O. (1995), *Empresas, contratos y estructura financiera*, Clarendon Press.

Hart, O. y J. Moore (1988), "Contratos incompletos y renegociación", *Econometrica* 56(4): 755–785.

Harvey, CR (2016), "Criptoфинanzas", disponible en SSRN.

Harvey, CR, A. Ramachandran y J. Santoro (2021), *DeFi y el futuro de las finanzas*, John Wiley & Sons.

Hau, H., Y. Huang, C. Lin, H. Shan, Z. Sheng y L. Wei (2024), "Crédito FinTech y crecimiento empresarial", *The Journal of Finance* 79(5): 3309-60.

Healy, PM y KG Palepu (2001), "Asimetría de la información, divulgación corporativa y los mercados de capitales: una revisión de la literatura sobre divulgación empírica", *Journal of Accounting and Economics* 31(1-3): 405–440.

Hendershott, T., CM Jones y AJ Menkveld (2011), "¿El trading algorítmico mejora la liquidez?", *Journal of Finance* 66: 1–33.

Hennessy, CA y CA Goodhart (2023), "La ley de Goodhart y el aprendizaje automático: una perspectiva estructural", *International Economic Review* 64(3): 1075–1086.

Hirshleifer, D. y SH Teoh (2003), "Atención limitada, divulgación de información e informes financieros", *Journal of Accounting and Economics* 36: 337-386.

Hoff, KA y M. Bashir (2015), "Confianza en la automatización: integración de evidencia empírica sobre los factores que influyen en la confianza", *Human Factors* 57(3): 407-434.

Huang, J. (2018), "El cliente sabe más: el valor de inversión de las opiniones de los consumidores", *Journal of Financial Economics* 128: 164-182.

Huang Y., L. Zhang, Z. Li, H. Qiu, T. Sun y X. Wang (2020), "Evaluación del riesgo crediticio de fintech para pymes: evidencia de China", Documento de trabajo del FMI 193.

Hué S., C. Hurlin, C. Perignon y S. Saurin (2023), "Medición de las fuerzas impulsoras del rendimiento predictivo: aplicación a la calificación crediticia", [arXiv.org, 2212.05866](https://arxiv.org/abs/2212.05866).

Hurlin, C., C. Perignon y S. Saurin (2024), "La imparcialidad de los modelos de calificación crediticia", *Management Science*, próximamente.

IIF-EY – Instituto de Finanzas Internacionales y EY (2025), Informe de la encuesta anual del IIF-EY sobre el uso de IA/ML en los servicios financieros: Resumen público, enero.

FMI – Fondo Monetario Internacional (2024), Mantener el rumbo: Incertidumbre, inteligencia artificial y estabilidad financiera, Informe sobre la estabilidad financiera mundial, octubre de 2024.

Imperva (2024), Bad Bot Report, abril.

Investigación de análisis de IoT (2023), Informe de mercado de IA generativa 2023-2030.

Jagtiani, J. y C. Lemieux (2019), “Los roles de los datos alternativos y el aprendizaje automático en los préstamos fintech: evidencia de la plataforma de consumo Lending Club”, *Financial Management* 48(4): 1009-1029.

Jame, R., R. Johnston, S. Markov y M. Wolfe (2016), “El valor de las previsiones de ganancias realizadas mediante colaboración colectiva”, *Journal of Accounting Research* 54: 1077–1109.

Jansen, M., HQ Nguyen y A. Shams (2024), “El auge de las máquinas: el impacto de la suscripción automatizada”, *Management Science*, próximamente.

Jensen, M. y WH Meckling (1976), “Teoría de la empresa: comportamiento gerencial, costos de agencia y estructura de propiedad”, *Journal of Financial Economics* 3(4): 305–360.

Jiang, J., K. Srinivasan y Y. Huang (2025a), “El impacto de GenAI en la creación de contenido: evidencia de videos musicales”, disponible en SSRN.

Jiang, W., J. Park, R. Xiao y S. Zhang (2025b), “IA y jornada laboral extendida: productividad, eficiencia de contratación y distribución de rentas”, documento de trabajo, Universidad Emory.

Jin, S. (2023), “Más que palabras: ¿Puede el tono de las reseñas de productos de consumo ayudar a predecir los fundamentos de las empresas?”, *Journal of Business Finance and Accounting* 50: 1910–1942.

John, K., L. Kogan y F. Saleh (2023), “Contratos inteligentes y finanzas descentralizadas”, *Annual Review of Financial Economics* 15: 523–542.

Johnson, J., A. Rhodes y M. Wildenbeest (2023), “Diseño de plataformas cuando los vendedores utilizan algoritmos de precios”, *Econometrica* 91: 1841-1879.

JP Morgan (2019), Manual de datos alternativos.

Kamenetsky Yadan, S. (2021), “Métodos y herramientas de detección de anomalías para big data”, *Boletín IFC* 57.

Katona Z, MO Painter, PN Patatoukas y J. Zeng (2025), “Sobre las consecuencias del big data en el mercado de capitales: evidencia del espacio exterior”, *Journal of Financial and Quantitative Analysis* 60: 551-579.

Kelly, B. y D. Xiu (2023), “Aprendizaje automático financiero”, *Fundamentos y tendencias® en finanzas* 13: 205-363.

Khandani, A., A. Kim y A. Lo (2010), "Modelos de riesgo crediticio del consumidor mediante algoritmos de aprendizaje automático", *Journal of Banking and Finance* 4(11): 2767–87.

Kim, A., M. Muhn y V. Nikolaev (2024), "Análisis de estados financieros con modelos de lenguaje grandes", Documento de trabajo de Fama-Miller, Chicago Booth.

Klein, T. (2021), "Colusión algorítmica autónoma: Q-learning bajo fijación de precios secuencial", *Rand Journal of Economics* 52: 538-599.

Korinek A. y A. Balwit (2024), "¿Alineados con quién? Objetivos directos y sociales para sistemas de IA", en J. Bullock et al. (eds.), *Oxford Handbook of AI Governance*, Oxford University Press.

Korinek, A. y J. Vipra (2024), "Concentrando inteligencia: escalamiento y estructura de mercado en inteligencia artificial", *Economic Policy* 40(121): 225-256.

Kozak, S., S. Nagel y S. Santosh (2020), "Reduciendo la sección transversal", *Journal of Financial Economics* 135: 271-292.

Kysucky, V. y L. Norden (2016), "Los beneficios de los préstamos relacionales en un contexto transnacional: un metaanálisis", *Management Science* 62(1): 90–110.

Lehar, A. y CA Parlour (2023), "Batalla de los bots: préstamos flash, valor extraíble de los mineros y liquidación eficiente", disponible en SSRN.

Leland, HE y DH Pyle (1977), "Asimetrías informativas, estructura financiera e intermediación financiera", *Journal of Finance* 32(2): 371–387.

Lessmann, S., B. Baesens, H. Seow y L. Thomas (2015), "Evaluación comparativa de algoritmos de clasificación de última generación para la calificación crediticia: una actualización de la investigación", *European Journal of Operational Research* 247: 124-136.

Levi, SD y AB Lipton (2018), "Una introducción a los contratos inteligentes y sus limitaciones potenciales e inherentes", Foro sobre Gobierno Corporativo de la Facultad de Derecho de Harvard, 26 de mayo.

Levy, G. y R. Razin (2015) "Negligencia de correlación, comportamiento electoral y agregación de información", *American Economic Review* 105(4): 1634–1645.

Levy, G., IM de Barreda y R. Razin (2022), "Persuasión con descuido de la correlación: un resultado de manipulación completa", *American Economic Review: Insights* 4(1): 123–138

Lewis, M. (2014), *Flash boys: una revuelta en Wall Street*, WW Norton & Company.

Liu, Y., y H. Wang (2024), "¿Quién está usando IA generativa?", Documento de trabajo de investigación sobre políticas 10870, Banco Mundial.

Liu, L., G. Lu y W. Xiong (2022): "El modelo de préstamos de las grandes tecnológicas", Documento de trabajo del NBER 30160.

- Liu, J., I. Makarov y A. Schoar (2023), "Anatomía de una carrera: el accidente de Terra Luna. Informe técnico", Documento de trabajo NBER 31160.
- Lopez-Lira, A. y Y. Tang (2023), "¿Puede ChatGPT pronosticar los movimientos del precio de las acciones? "Predicibilidad de retorno y modelos de lenguaje grandes", disponible en SSRN.
- Loughran, T. y B. McDonald (2011), "¿Cuándo un pasivo no es un pasivo? Análisis textual, diccionarios y formularios 10-K", *Journal of Finance* 66(1): 35–65.
- Lumsdaine, RL y RJD Potter van Loon (2018), "¿Coinciden las probabilidades de las encuestas con las creencias del mercado financiero?", *Journal of Behavioral Finance* 19(2): 209-220.
- Lyonnet, V. y L. Stern (2024), "Aprendizaje automático sobre opciones de capital de riesgo", disponible en SSRN.
- MacKay, A. y S. Weinstein (2022), "Algoritmos de precios dinámicos, daño al consumidor y respuesta regulatoria", Documento de trabajo 22-050, Harvard Business School.
- Makarov, I. y A. Schoar (2022), "Criptomonedas y finanzas descentralizadas (DeFi)", Documento de trabajo NBER 30006.
- Matz, SC, JD Teeny, SS Vaid et al. (2024), "El potencial de la IA generativa para la persuasión personalizada a escala", *Scientific Reports* 14: 4692.
- Mercer (2024), Integración de IA en la gestión de inversiones.
- Mester, LJ, LI Nakamura y M. Renault (2007), "Cuentas de transacciones y monitoreo de préstamos", *Review of Financial Studies* 20(3): 529–556.
- Morris, MR, J. Sohl-Dickstein, N. Fiedel, T. Warkentin, A. Dafoe, A. Faust, C. Farabet y S. Legg (2024), "Niveles de IAG: Operacionalización del progreso en el camino hacia la IAG", en *Actas de la 41.ª Conferencia Internacional sobre Aprendizaje Automático*.
- Müller, K. y E. Verner (2024), "Asignación de crédito y fluctuaciones macroeconómicas", *The Review of Economic Studies* 91(6): 3645–76.
- Murray, S., Y. Xia y H. Xiao (2024), "Gráficos por máquinas", *Journal of Financial Economics* 153: 1037-1091.
- Myers, SC y NS Majluf (1984), "Financiación corporativa y decisiones de inversión cuando las empresas tienen información que los inversores no tienen", *Journal of Financial Economics* 13(2): 187–221.
- Nagel, S. (2021), *Aprendizaje automático en la fijación de precios de activos*, Princeton University Press.
- Narang, N. (2013), *Dentro de la caja negra*, Wiley.
- NIST – Instituto Nacional de Estándares y Tecnología (2023), "Marco de gestión de riesgos de inteligencia artificial (AI RMF 1.0)".

Nordhaus, W. (2021), "¿Nos acercamos a una singularidad económica? La tecnología de la información y el futuro del crecimiento económico", *American Economic Journal: Macroeconomics* 13: 299–332.

194

Noy, S. y W. Zhang (2023), "Evidencia experimental sobre los efectos de la inteligencia artificial generativa en la productividad", *Science* 381(6654): 187-192.

OCDE – Organización para la Cooperación y el Desarrollo Económicos (2017), *Algoritmos y colusión: Política de competencia en la era digital*, OECD Publishing.

OCDE (2021), *Inteligencia artificial, aprendizaje automático y big data en finanzas: oportunidades, desafíos e implicaciones para los responsables de políticas*, Publicaciones de la OCDE.

OCDE (2024), "¿Milagro o mito? Evaluación de las ganancias de productividad macroeconómica derivadas de la inteligencia artificial", *Documentos de Inteligencia Artificial de la OCDE*, 29 de noviembre.

Ofcom (2023), *Estudio de mercado de servicios en la nube*, Informe final.

O'Hara, M. (2014), "El trading de alta frecuencia y su impacto en los mercados", *Financial Analysts Journal* 70(3): 18-27.

OpenAI (2025), "Operador" (<https://openai.com/index/introducing-operator/>).

Ornelas, J. y A. Pecora (2022), "¿Reducen los préstamos fintech los costos de financiamiento? Evidencia de un mercado emergente", *Documento de Trabajo del Banco Central de Brasil* 571.

Pagano, M. y T. Jappelli (1993), "Intercambio de información en los mercados de crédito", *Journal of Finance* 48(5): 1693–18.

Pagnotta, ES y T. Philippon (2018), "Competir en velocidad", *Econometrica* 86: 1067-1115.

Parton, M., Angelone, M., Metta, C., et al. (2022), "Inteligencia artificial y renegociación de contratos de arrendamiento comercial afectados por contingencias relacionadas con la pandemia de COVID-19. El proyecto aiaco", *arXiv:2210.09515*.

Peng, S., W. Swiatek, A. Gao, P. Cullivan y H. Chang, H (2024), "Revolución de la IA en los chatbots: evidencia de un experimento controlado aleatorio", *preimpresión de arXiv*, *arXiv:2401.10956*.

Peress, J. (2014), "Aprendiendo de los precios de las acciones y el crecimiento económico", *Review of Financial Studies* 27: 2998-3059.

Philippon, T. (2015), "¿Se ha vuelto menos eficiente el sector financiero estadounidense? Sobre la teoría y la medición de la intermediación financiera", *American Economic Review* 105: 1408-1438.

Phillipon, T. (2020), "Sobre tecnología financiera e inclusión financiera", *Documento de trabajo del BPI* 841.

- Rajan, RG (1992), "Insiders and outsiders: La elección entre deuda informada y deuda independiente", *Journal of Finance* 47(4): 1367–1400.
- Rampini, AA y S. Viswanathan (2013), "Garantía y estructura de capital", *Journal of Financial Economics* 109(2): 466–492.
- Reimann, M., O. Schilke y KS Cook (2017), "La confianza es hereditaria, mientras que la desconfianza no lo es", *Actas de la Academia Nacional de Ciencias* 114(27): 7007-7012.
- Retterath, A. (2020), "Humano versus computadora: evaluación comparativa de capitalistas de riesgo y algoritmos de aprendizaje automático para la selección de inversiones", disponible en SSRN.
- Ross, S. (1973), "La teoría económica de la agencia: el problema del director", *American Economic Review* 63: 134–139.
- Ross, S. (1977), "La determinación de la estructura financiera: el enfoque de señalización de incentivos", *Bell Journal of Economics* 8: 23–40.
- Rossi, A. y S. Utkus (2024), "Los efectos de diversificación y bienestar del robo-advising", *Journal of Financial Economics* 157: 1038-1069.
- Rubio, J., P. Barucca, G. Gage, J. Arroyo y R. Morales-Resendiz (2021), "Clasificación de patrones de pago con redes neuronales artificiales: un enfoque de autocodificador", *Boletín IFC* 57.
- Russell, S. (2020), *Compatible con humanos: inteligencia artificial y el problema del control*, Penguin Books.
- Sabetti, L. y R. Heijmans (2020), "¿Superficial o profundo? Detección de flujos anómalos en el sistema canadiense de compensación y liquidación automatizada mediante un autocodificador", Documento de trabajo 681 del Banco de los Países Bajos.
- Scheurer, J., M. Balesni y M. Hobbhahn (2023), "Informe técnico: Los modelos de lenguaje grandes pueden engañar estratégicamente a sus usuarios cuando se les somete a presión", preimpresión de arXiv, arXiv:2311.07590.
- SEC – Comisión de Bolsa y Valores de Estados Unidos (2023), "Conflictos de intereses asociados con el uso de análisis de datos predictivos por parte de corredores de bolsa y asesores de inversiones", Comunicado n.º 34-97990.
- Sheng, J., Z. Sun, B. Yang y A. Zhang (2024), "IA generativa y gestión de activos", documento de trabajo, Universidad de California, Irvine.
- Shiller, RJ (1988), "El seguro de cartera y otras modas de los inversores como factores en el colapso del mercado de valores de 1987", *NBER Macroeconomics Annual* 3: 287–297.
- Shkilko, A. y K. Sokolov (2020), "No hay mal que por bien no venga: Comercio rápido, conectividad por microondas y costos comerciales", *The Journal of Finance* 75: 2899-2927.

- Stiglitz, J. (1994), "El papel del Estado en los mercados financieros", en Actas de la Conferencia Anual del Banco Mundial sobre Economía del Desarrollo.
- Stiglitz, JE y A. Weiss (1981), "Racionamiento del crédito en mercados con información imperfecta", *American Economic Review* 71: 393–410.
- Stiglitz, JE. y A. Weiss (1988), "Los bancos como contadores sociales y dispositivos de selección para la asignación de crédito", Documento de trabajo del NBER 2710.
- Suleyman, M. y M. Bhaskar (2023), *La ola que viene: tecnología, poder y el mayor dilema del siglo XXI*, Crown.
- Sundaresan, S. y Z. Wang (2015), "Sobre el diseño de capital contingente con un disparador de mercado", *Journal of Finance* 70(2): 881–920.
- Sutton, R., y A. Barto (2019), *Aprendizaje por refuerzo*, MIT Press.
- Szabo, N. (1994), "Contratos inteligentes", documento de trabajo, Universidad de Ámsterdam.
- Tan, J., CK Shum y M. Akmal Amri (2021), "Aplicación para redactar cartas de supervisión: agiliza la redacción de cartas y mantiene el tono uniforme", *Boletín IFC* 57.
- Tang, VW (2018), "Sabiduría de las multitudes: variación transversal en el carácter informativo de la información de productos generada por terceros en Twitter", *Journal of Accounting Research* 56: 989–1034.
- Tang, H. (2019), "Prestamistas entre pares versus bancos: ¿sustitutos o complementos?", *Review of Financial Studies* 32(5): 1900-1938.
- Timmermann, A. (2006), "Combinaciones de pronósticos", en G. Elliott, CWJ Granger y A. Timmermann (eds), *Manual de pronósticos económicos*, Vol. I, Elsevier.
- Departamento del Tesoro de Estados Unidos (2016), "Oportunidades y desafíos en los préstamos en el mercado en línea", mayo.
- van Binsbergen, J., X. Han y Lopez-Lira (2023), "El hombre versus el aprendizaje automático: la estructura temporal de las expectativas de ganancias y los sesgos condicionales", *The Review of Financial Studies* 36: 2361–2396.
- Verrecchia, RE (1982), "Adquisición de información en una economía ruidosa de expectativas racionales", *Econometrica* 50: 1415–1430.
- Vives, X. (2019), "Disrupción digital en la banca", *The Annual Review of Financial Economics* 11: 243-272.
- Vives, X. y Z. Ye (2025a), "Tecnología de la información y competencia entre prestamistas", *Journal of Financial Economics* 163, 103957
- Vives, X. y Z. Ye (2025b), "Entrada de tecnología financiera, competencia en el mercado crediticio y bienestar", *Journal of Financial Economics*, de próxima publicación.

Wah, E. (2016), "¿Cuán frecuentes y rentables son las oportunidades de arbitraje de latencia en las bolsas de valores de Estados Unidos?", Disponible en SSRN.

Wang, X., RJ Hyndman, F. Li y Y. Kang (2023), "Combinaciones de pronósticos: una revisión de más de 50 años", *International Journal of Forecasting* 39: 1518-1547.

Watkins, C. y P. Dayan (1992), "Q-learning", *Aprendizaje automático* 8: 279-292.

Weller, B. (2018), "¿Reduce el trading algorítmico la adquisición de información?", *The Review of Financial Studies* 31: 2184–2226

Woodward, M. (2018), "Aumentar la competencia: la influencia del aumento de velocidad del IEX en los mercados financieros de EE. UU.", disponible en SSRN.

Yampratoom, E. (2024), "Experiencias de la implementación de casos de uso empresarial con IA generativa", *Foro de Liderazgo en Tecnología de Banca Central*, 4-5 de diciembre.

Yermack, D. (2017), "Gobierno corporativo y cadenas de bloques", *Review of Finance* 21(1): 7–31.

Yi, HC, D. Choi y Y. Kim (2022), "Modelo de factor dinámico y algoritmo de aprendizaje profundo para la predicción del PIB", *Bank of Korea Economic Analysis* 28(2).

Yu, H., X. Hao, L. Wu, Y. Zhao y Y. Wang (2023), "Ojo en el espacio exterior: imágenes satelitales de puertos de contenedores pueden predecir el retorno de las existencias mundiales", *Humanities and Social Sciences Communications* 10: 1–16.

Zhang, Y. (2024), "¿Se benefician los fondos mutuos de la adopción de tecnología de IA?", *Documento de investigación de la HKUST Business School* n.º 2024-165.

Zhu, C. (2019), "Big data como mecanismo de gobernanza", *The Review of Financial Studies* 32(5): 2021–2061.



El séptimo informe de la serie El Futuro de la Banca, parte de la Iniciativa Bancaria de la IESE Business School, examina las transformaciones fundamentales inducidas

por la inteligencia artificial y los desafíos políticos que plantea. Se centra en tres temas principales: el uso de

La IA en la intermediación financiera, la banca central y las políticas, y los desafíos regulatorios; las implicaciones de la abundancia de datos y el comercio algorítmico para los mercados financieros; y los efectos de la IA en las finanzas corporativas, la contratación y la gobernanza. En estos ámbitos, el informe enfatiza que, si bien la IA tiene el potencial de mejorar la eficiencia, la inclusión y la resiliencia, también plantea nuevas vulnerabilidades que exigen respuestas regulatorias adaptativas.

ISBN: 978-1-912179-93-0

ISBN 978-1-912179-93-0



9 781912 179930 >

187 boulevard Saint-Germain | 75007 PARIS | FRANCIA

2 Coldbath Square | LONDRES EC1R 5HL | Reino Unido

TELÉFONO: +44 (0)20 7183 8801 | FAX: +44 (0)20 7183 8820

CORREO ELECTRÓNICO: CEPR@CEPR.ORG

WWW.CEPR.ORG