

Editorial Mar Caribe

MÉTODOS ESTADÍSTICOS CON INTELIGENCIA ARTIFICIAL APLICADOS A CRIPTOMONEDAS Y FINANZAS DESCENTRALIZADAS

Escrito por:

**Carolina Montes Lizárraga
Remo Choquejahua Acero
Enrique Gabriel Pongo Mendo
Luis Centeno Ramírez
Luis Enrique Ramirez Milla
Joaquin Alvarez Carrillo
Daisy Mestas Yucra**

ISBN: 978-9915-698-55-7



Métodos estadísticos con inteligencia artificial aplicados a criptomonedas y finanzas descentralizadas

Montes Lizárraga, Carolina; Choquejahua Acero, Remo; Pongo Mendo, Enrique Gabriel; Centeno Ramírez, Luis; Ramirez Milla, Luis Enrique; Alvarez Carrillo, Joaquin; Mestas Yucra, Daisy

© *Montes Lizárraga, Carolina; Choquejahua Acero, Remo; Pongo Mendo, Enrique Gabriel; Centeno Ramírez, Luis; Ramirez Milla, Luis Enrique; Alvarez Carrillo, Joaquin; Mestas Yucra, Daisy, 2025*

Primera edición (1ra. ed.): Diciembre, 2025

Editado por:

Editorial Mar Caribe ®

www.editorialmarcaribe.es

Av. Gral. Flores 547, 70000 Col. del Sacramento, Departamento de Colonia, Uruguay.

Diseño de caratula e ilustraciones: *Isbelia Salazar Morote*

Libro electrónico disponible en:

<https://editorialmarcaribe.es/ark:/10951/isbn.9789915698557>

Formato: Electrónico

ISBN: 978-9915-698-55-7

ARK: ark:/10951/isbn.9789915698557

[Editorial Mar Caribe \(OASPA\)](#): Como miembro de la Open Access Scholarly Publishing Association, apoyamos el acceso abierto de acuerdo con el código de conducta, transparencia y mejores prácticas de OASPA para la publicación de libros académicos y de investigación. Estamos comprometidos con los más altos estándares editoriales en ética y deontología, bajo la premisa de «Ciencia Abierta en América Latina y el Caribe»



Editorial Mar Caribe, firmante Nº 795 de 12.08.2024 de la [Declaración de Berlín](#)

“... Nos sentimos obligados a abordar los retos de Internet como medio funcional emergente para la distribución del conocimiento. Obviamente, estos avances pueden modificar significativamente la naturaleza de la publicación científica, así como el actual sistema de garantía de calidad....” (Max Planck Society, ed. 2003., pp. 152-153).



[CC BY-NC 4.0](#)

Los autores pueden autorizar al público en general a reutilizar sus obras únicamente con fines no lucrativos, los lectores pueden utilizar una obra para generar otra, siempre que se dé crédito a la investigación, y conceden al editor el derecho a publicar primero su ensayo bajo los términos de la licencia CC BY-NC 4.0.



Editorial Mar Caribe se adhiere a la “Recomendación relativa a la preservación del patrimonio documental, comprendido el patrimonio digital, y el acceso al mismo” de la UNESCO y a la Norma Internacional de referencia para un sistema abierto de información archivística ([OAIS-ISO 14721](#)). Este libro está preservado digitalmente por [ARAMEO.NET](#)



Editorial Mar Caribe

**Métodos estadísticos con inteligencia artificial
aplicados a criptomonedas y finanzas
descentralizadas**

Colonia, Uruguay

2025

Índice

| | |
|--|----|
| Introducción..... | 8 |
| Capítulo I..... | 12 |
| Análisis econométrico avanzado de los mecanismos de oferta y demanda en los mercados globales..... | 12 |
| El paradigma estructural y el desafío de la simultaneidad | 12 |
| Fundamentos de los modelos de ecuaciones simultáneas (SEM) | 13 |
| Métodos de estimación de información limitada y completa | 14 |
| Avances en el Método Generalizado de Momentos (GMM) y endogeneidad dinámica..... | 15 |
| GMM frente a estimadores clásicos en presencia de heterocedasticidad..... | 15 |
| Endogeneidad dinámica en datos de panel | 16 |
| Dinámica de series temporales y transmisión de precios internacionales | 16 |
| Cointegración y modelos de corrección de errores (VECM)..... | 17 |
| El enigma de la autocorrelación en modelos de almacenamiento | 17 |
| Interdependencia global y el modelo Global VAR (GVAR)..... | 18 |
| Estructura y resolución de la dimensionalidad..... | 18 |
| Dinámica de spillovers: El caso de China | 19 |
| Modelos de Equilibrio General Dinámico Estocástico (DSGE) de economía abierta | 19 |
| El modelo SIGMA y la política monetaria global..... | 20 |
| Identificación de choques en periodos de crisis | 20 |
| Heterogeneidad de agentes y modelos HANK | 21 |
| Transmisión de la demanda y Propensión Marginal al Consumo (MPC)..... | 21 |
| Aplicación al mercado inmobiliario y alquileres..... | 22 |
| Frontera tecnológica: Machine Learning y Big Data en la economía global | 22 |
| Nowcasting del comercio mundial con conjuntos de datos masivos..... | 23 |
| Double Machine Learning (DML) para elasticidades de precio | 24 |
| Casos de estudio sectoriales: Energía y minerales críticos | 24 |
| El mercado petrolero: Agotamiento y elasticidad estructural | 24 |

| | |
|---|----|
| La econometría de los minerales críticos (Litio, Cobre, Níquel) | 25 |
| Spillovers de mercados emergentes y política comercial | 26 |
| Modelos de gravedad y sorpresas de crecimiento | 26 |
| El auge del proteccionismo comercial..... | 27 |
| Modelización de constructos latentes en el comercio internacional | 27 |
| Integración de análisis de factores y diagramas de ruta..... | 27 |
| Conclusiones sobre la frontera econométrica global..... | 28 |
| Capítulo II..... | 30 |
| Hacia una Nueva Gobernanza Económica Basada en Datos | 30 |
| El Cambio de Paradigma: Los Datos como Activo Estratégico | 30 |
| Marcos Internacionales y el Contrato Social para los Datos..... | 31 |
| Recomendaciones de la OCDE y la Unión Europea | 32 |
| La Estrategia de Transformación Digital del Perú al 2030 | 33 |
| El Rol de la Secretaría de Gobierno y Transformación Digital | 33 |
| Gobernanza Fiscal y Aduanera Inteligente: El Caso de la SUNAT | 34 |
| El Arsenal Digital de la SUNAT y la Fiscalización Predictiva | 34 |
| Comparativa Internacional en Recaudación y Big Data | 35 |
| Innovación Monetaria y el Proyecto de CBDC del BCRP | 35 |
| Pilotos de Dinero Digital y Resultados Regionales | 36 |
| Interoperabilidad: La Clave del Flujo de Datos en el Estado | 36 |
| El Benchmarking de Estonia y el Sistema X-Road..... | 37 |
| La Plataforma de Interoperabilidad del Estado (PIDE) en Perú | 37 |
| Desafíos Estructurales: Informalidad y Brecha Regional | 38 |
| El Impacto de la Informalidad en la Productividad | 38 |
| La Digitalización como Motor de Formalización | 39 |
| Tecnologías de Vanguardia: Blockchain, IoT y Gestión de Crisis | 39 |
| Blockchain y la Seguridad del Dato | 39 |
| Lecciones de la Gestión de Crisis (COVID-19) | 40 |
| Ética, Privacidad y Soberanía Digital | 40 |
| Desafíos Éticos y Sesgos Algorítmicos..... | 40 |

| | |
|--|----|
| Ciberseguridad y Protección de Datos Personales | 41 |
| Hacia una Síntesis de la Nueva Gobernanza Económica | 41 |
| Capítulo III..... | 43 |
| Integración de la Inteligencia Artificial en la Previsión de Flujos Comerciales: | |
| Transformación de la Macroeconómica Global y Operativa (2025-2040) | 43 |
| Dinámicas Macroeconómicas y el Papel de la Inteligencia Artificial en 2025 | 43 |
| Arquitecturas de Aprendizaje Profundo para la Previsión de Series Temporales . | 45 |
| Redes Recurrentes: LSTM y GRU | 45 |
| Transformers y Modelado de Largo Alcance | 47 |
| El Ecosistema de Datos Alternativos en el Comercio Exterior | 47 |
| Imágenes Satelitales e Inteligencia Geoespacial | 48 |
| El Papel de la Inteligencia de Documentos y el Procesamiento de Lenguaje | |
| Natural (NLP) | 48 |
| Inteligencia Artificial en las Finanzas Comerciales y Fintech | 49 |
| Modelos de Calificación Crediticia Basados en IA | 49 |
| Iniciativas de Interoperabilidad Transfronteriza: Proyecto Aperta | 50 |
| Optimización Operativa y Resiliencia en la Cadena de Suministro | 50 |
| Previsión de la Demanda y Gestión de Inventarios | 51 |
| Visibilidad Predictiva y Gestión de Excepciones | 51 |
| Metodologías de Proyección Macroeconómica: El Modelo GIMF del FMI | 51 |
| Estructura del Modelo GIMF para la IA | 52 |
| Resultados de la Simulación y Desigualdad Global | 52 |
| El Impacto en el Mercado Laboral y la Estructura de Costos..... | 53 |
| Sustitución de Tareas y Primas Salariales | 53 |
| La Fuerza Laboral en Países en Desarrollo | 54 |
| Desafíos Técnicos: Silos de Datos y Fragmentación Regulatoria..... | 54 |
| Causas y Consecuencias de los Silos..... | 55 |
| Aprendizaje Federado como Solución de Privacidad | 55 |
| El Marco Regulatorio Global: De la Innovación a la Restricción | 56 |
| La Ley de IA de la UE y sus Implicaciones Comerciales | 56 |

| | |
|--|----|
| AI Convergence vs. AI Divergence..... | 57 |
| Conclusiones y Perspectivas Estratégicas hacia 2040..... | 57 |
| Capítulo IV | 59 |
| Análisis Técnico y Sistémico de Métodos Estadísticos e Inteligencia Artificial en Estructuras Económicas No Fiduciarias..... | 59 |
| Fundamentos de la Economía No Fiduciaria y la Gestión Técnica de Recursos.... | 59 |
| Comparativa Estructural de Sistemas Económicos y sus Mecanismos de Control | 60 |
| Modelado Estadístico y Aprendizaje Automático para la Predicción de Volatilidad | 61 |
| Evolución hacia Modelos de Aprendizaje Automático y Redes Neuronales | 62 |
| IA y Aprendizaje por Refuerzo en la Optimización de Tokenomics | 63 |
| Mecanismos de Estabilización Algorítmica y DAOs | 64 |
| Integridad y Seguridad en Redes Descentralizadas: Detección de Anomalías | 65 |
| Metodologías de Detección y Evaluación de Modelos | 65 |
| El Papel de la Simulación y los Datos Sintéticos en la Resiliencia Económica | 66 |
| Privacidad y Cumplimiento mediante Aprendizaje Federado | 66 |
| Optimización de la Asignación de Recursos Físicos y Digitales | 67 |
| Desafíos Metodológicos y Complejidad Socio-Técnica..... | 68 |
| La Paradoja de la Estabilidad Algorítmica..... | 68 |
| Hacia una Nueva Gobernanza Económica Basada en Datos | 69 |
| Capítulo V..... | 71 |
| Métodos estadísticos con inteligencia artificial aplicados a plataformas Fintech..... | 71 |
| Evolución y maduración del ecosistema Fintech global | 71 |
| Metodologías estadísticas y aprendizaje automático en la gestión del riesgo crediticio..... | 73 |
| Comparativa de desempeño entre modelos tradicionales y avanzados | 73 |
| Optimización y validación estadística de los modelos | 74 |
| Detección de fraude y análisis de anomalías en tiempo real..... | 75 |
| Arquitecturas para el análisis de series temporales | 76 |
| Biometría conductual y redes de grafos (GNN) | 76 |

| | |
|---|----|
| Inteligencia artificial en el asesoramiento robótico y la gestión patrimonial | 77 |
| Optimización de carteras más allá de la media-varianza | 78 |
| Aprendizaje por refuerzo y mitigación de sesgos | 78 |
| Procesamiento de lenguaje natural y análisis de sentimiento financiero | 79 |
| Evolución hacia la fusión bayesiana de modelos de lenguaje | 79 |
| Aplicaciones estratégicas del NLP | 80 |
| Trading de alta frecuencia (HFT) y sistemas multi-agente | 81 |
| La revolución de JaxMARL-HFT y la aceleración por GPU | 81 |
| Inteligencia artificial explicable (XAI) y el nuevo marco regulatorio | 82 |
| Técnicas y principios de la XAI en finanzas | 83 |
| Casos de estudio y líderes del mercado: Nubank, Revolut y la infraestructura de pagos | 83 |
| Nubank: Dominancia en América Latina mediante analítica profunda | 84 |
| Revolut: La super-app financiera global | 84 |
| Infraestructura de pagos: Stripe y Square | 85 |
| Conclusiones y perspectiva hacia la segunda mitad de la década | 85 |
| Conclusión | 87 |
| Bibliografía | 89 |

Introducción

A medida que el año 2025 avanza, el mercado de criptomonedas y las finanzas descentralizadas (DeFi) han trascendido su fase de experimentación para consolidarse como componentes estructurales del sistema financiero global. Esta evolución no ha sido puramente impulsada por la especulación, sino por una sofisticación tecnológica que permite procesar volúmenes masivos de datos en tiempo real, utilizando arquitecturas de inteligencia artificial (IA) que superan las capacidades analíticas de los modelos econométricos tradicionales. El presente informe de investigación actúa como una introducción exhaustiva a los métodos que definen esta era, analizando desde la modelización estocástica de la volatilidad hasta el despliegue de agentes autónomos agénticos en protocolos de liquidez.

Durante décadas, el análisis de mercados financieros se fundamentó en la Hipótesis de los Mercados Eficientes (EMH), que postula que los precios reflejan toda la información disponible de manera instantánea. No obstante, la volatilidad extrema y las dinámicas de red intrínsecas a los activos digitales han desafiado estas nociones. La transición hacia el año 2025 ha evidenciado que los mercados de criptomonedas, aunque cada vez más maduros, operan bajo regímenes de ineficiencia relativa donde los patrones no lineales y las dependencias de largo plazo ofrecen oportunidades de arbitraje y predicción inalcanzables para los modelos lineales básicos como el ARIMA (Autoregressive Integrated Moving Average).

La insuficiencia de los modelos tradicionales radica en su incapacidad para capturar las "colas pesadas" (fat-tails) y los saltos bruscos de precios provocados por eventos exógenos, como cambios regulatorios o movimientos coordinados de grandes tenedores. En este contexto, la inteligencia artificial, particularmente a través del aprendizaje profundo (Deep Learning), permite modelar la complejidad del mercado

mediante redes neuronales que no requieren supuestos previos sobre la distribución de los datos.

Uno de los pilares fundamentales de esta investigación es la aplicación de modelos estadísticos para la gestión del riesgo. La volatilidad de Bitcoin, por ejemplo, registró un promedio intradía del 3.8% entre 2020 y 2022, comparado con el 0.7% del S&P 500, una disparidad que exige herramientas de medición de precisión extrema. El uso de modelos GARCH (Generalized Autoregressive Conditional Heteroskedasticity) sigue siendo relevante para la estimación de la varianza condicional, pero en 2025 estos se han integrado en marcos de redes neuronales (GARCH-DL) para mejorar su capacidad reactiva ante choques de liquidez.

La modelización bayesiana ha resurgido como una herramienta vital para la actualización de probabilidades en entornos de incertidumbre. Mediante la regresión bayesiana, los inversores institucionales pueden ajustar sus expectativas de precio en función de nuevas evidencias, como flujos de entrada en ETFs de Bitcoin o cambios en las tasas de interés de los bancos centrales.

El trading de criptomonedas en 2025 está dominado por sistemas que operan en milisegundos, donde la velocidad de procesamiento de datos on-chain y off-chain es la métrica de éxito definitiva. Estos sistemas emplean una arquitectura de " fusión multimodal", integrando datos estructurados (precios, volumen) con datos no estructurados (noticias, sentimiento en redes sociales).

El aprendizaje por refuerzo (RL) ha revolucionado la toma de decisiones dinámicas al permitir que un agente aprenda políticas óptimas de inversión a través de la interacción directa con el entorno de mercado. A diferencia del aprendizaje supervisado, el RL no requiere etiquetas de "correcto" o "incorrecto", sino que maximiza una función de recompensa acumulada, como el ratio de Sharpe o el retorno neto.

En 2025, el marco líder es el "prediction-decision framework", que utiliza una combinación de Gradient Boosting Regression Trees (GBRT) para la previsión a corto plazo y algoritmos de RL como Rainbow DQN o Soft Actor-Critic (SAC) para la ejecución de órdenes.

El ecosistema DeFi ha evolucionado de simples protocolos de intercambio a complejas infraestructuras de gobernanza y liquidez. El año 2025 marca la consolidación de protocolos como Sky (la evolución de MakerDAO), Aave y EigenLayer como los pilares de la nueva economía.

El año 2025 muestra un dinamismo particular en las regiones de habla hispana. España se ha consolidado como un centro de innovación Fintech en Europa, con ciudades como Madrid, Barcelona y Valencia albergando a cientos de empresas que integran IA y Blockchain. Los bancos tradicionales españoles, como Santander, lideran iniciativas de bonos verdes tokenizados, utilizando Blockchain para garantizar la transparencia en la financiación sostenible.

En Latinoamérica, el panorama es de adopción masiva impulsada por la necesidad de inclusión financiera y protección contra la inflación. Brasil, México, Colombia y Argentina se encuentran entre los líderes mundiales en adopción de criptomonedas.

La investigación presentada subraya que la aplicación de métodos estadísticos avanzados y técnicas de inteligencia artificial no es solo una ventaja competitiva, sino un requisito de supervivencia en el mercado criptográfico de 2025. Los modelos híbridos, que combinan el rigor de la econometría clásica con la potencia predictiva de las redes neuronales profundas, ofrecen el camino más sólido hacia la eficiencia del mercado.

Por ende, la integración de la computación cuántica presenta tanto el mayor riesgo como la mayor oportunidad. Mientras que el algoritmo de Shor amenaza con

comprometer las claves privadas actuales, la criptografía post-cuántica y el aprendizaje automático cuántico prometen llevar la velocidad y seguridad de las finanzas descentralizadas a niveles inimaginables.

En última instancia, el éxito de los "Métodos estadísticos con inteligencia artificial aplicados a criptomonedas y finanzas descentralizadas" dependerá de la capacidad de los investigadores y reguladores para colaborar en la creación de sistemas que no solo sean rentables, sino también éticos, transparentes y resilientes ante las tormentas del mercado digital. La transición hacia una economía agéntica, donde los humanos y la IA coexisten en la cadena de bloques, ya ha comenzado, y la modelización estadística es el lenguaje que permite traducir esa complejidad en decisiones financieras inteligentes.

Capítulo I

Análisis econométrico avanzado de los mecanismos de oferta y demanda en los mercados globales

La evolución de la economía global en la última década ha transformado radicalmente la manera en que los analistas y académicos abordan el estudio de los mercados. La interconexión sistémica, la volatilidad extrema en los precios de las materias primas y la emergencia de choques exógenos de gran escala, como la pandemia del COVID-19 y las tensiones geopolíticas en Eurasia, han dejado obsoletos los modelos de regresión lineal simples para el análisis de la oferta y la demanda. En este contexto, la econometría avanzada se ha consolidado como la disciplina fundamental para desentrañar las complejas relaciones causales, la dinámica de los precios y la propagación de desbordamientos internacionales (*spillovers*). El presente reporte analiza las metodologías de vanguardia empleadas en la modelización de mercados globales, integrando enfoques estructurales, dinámicos y computacionales que definen la frontera actual de la investigación macroeconómica y sectorial.

El paradigma estructural y el desafío de la simultaneidad

La determinación del precio y la cantidad en un mercado global no es un proceso unidireccional, sino el resultado de un sistema de interacciones simultáneas. Este fenómeno constituye el problema central de la endogeneidad en la econometría

de oferta y demanda.¹ Cuando el precio de una mercancía se determina por la intersección de las curvas de oferta y demanda, dicho precio está correlacionado con los términos de error de ambas ecuaciones. En consecuencia, el uso de Mínimos Cuadrados Ordinarios (OLS) produce estimadores sesgados e inconsistentes, ya que se viola el supuesto de exogeneidad de los regresores.¹

Fundamentos de los modelos de ecuaciones simultáneas (SEM)

Para abordar esta problemática, la teoría económica recurre a los Modelos de Ecuaciones Simultáneas (SEM). Estos modelos describen el comportamiento de una economía o mercado a través de un conjunto de ecuaciones estructurales que representan relaciones teóricas explícitas.¹ En un sistema típico, tenemos M variables endógenas, cuyos valores se determinan dentro del sistema, y K variables exógenas o predeterminadas, cuyos valores se consideran dados fuera del modelo.¹ La representación matricial de este sistema es:

$$Y \backslash \Gamma + X B = E$$

Donde Y es una matriz de variables endógenas de dimensión $T \times M$, X es una matriz de variables exógenas de dimensión $T \times K$, $\backslash \Gamma$ y B son las matrices de parámetros estructurales, y E es la matriz de perturbaciones estocásticas.¹ La identificación del modelo es un requisito previo para la estimación. Según la condición de orden, para que una ecuación esté identificada, el número de variables exógenas excluidas de dicha ecuación debe ser al menos igual al número de variables endógenas incluidas menos uno.³

La forma estructural del modelo refleja la teoría económica subyacente, pero para fines de estimación y pronóstico, a menudo se deriva la "forma reducida".¹ Al post-multiplicar la ecuación estructural por $\backslash \Gamma^{-1}$ (asumiendo que es no

singular), obtenemos:

$$Y = X \backslash P_i + V$$

Donde $\backslash P_i = -B \backslash \Gamma^{-1}$ es la matriz de parámetros de la forma reducida y $V = E \backslash \Gamma^{-1}$ es el nuevo término de error. Cada variable endógena se expresa ahora como una función lineal únicamente de las variables exógenas del sistema, lo que permite la aplicación de OLS de manera consistente en la forma reducida, aunque no necesariamente permite recuperar todos los parámetros estructurales a menos que el modelo esté exactamente identificado.¹

Métodos de estimación de información limitada y completa

La literatura econométrica ha desarrollado una jerarquía de estimadores para resolver el sesgo de simultaneidad, cada uno con diferentes propiedades de eficiencia y robustez. El método de Mínimos Cuadrados en Dos Etapas (2SLS) es la herramienta más común para la estimación de ecuaciones individuales dentro de un sistema.⁴ En la primera etapa, se regresan las variables endógenas explicativas sobre todos los instrumentos exógenos para obtener valores proyectados que, por construcción, están descorrelacionados con el término de error estructural. En la segunda etapa, se utiliza esta proyección como regresor para obtener estimadores consistentes del efecto causal.⁴

Sin embargo, cuando se busca eficiencia sistémica, el método de Mínimos Cuadrados en Tres Etapas (3SLS) supera al 2SLS. El 3SLS es un estimador de "información completa" que estima todas las ecuaciones simultáneamente, aprovechando la estructura de covarianza de los términos de error entre ecuaciones.⁴ Esto es particularmente relevante en mercados globales interconectados donde un

choque en la demanda de crudo en Asia puede estar correlacionado con un choque en la oferta de gas natural en Europa debido a factores macroeconómicos subyacentes no observados.⁶

El 3SLS se reduce a Mínimos Cuadrados Ordinarios si no hay endogeneidad y a Regresiones Aparentemente no Relacionadas (SUR) si todos los regresores son exógenos.⁵ Investigaciones empíricas indican que mientras el 3SLS ofrece mejores estimaciones asintóticas, en muestras pequeñas, métodos como el MVR (Multivariate Regression) pueden tener un desempeño superior.⁸

Avances en el Método Generalizado de Momentos (GMM) y endogeneidad dinámica

En las últimas décadas, el Método Generalizado de Momentos (GMM) ha emergido como el estándar de oro para el tratamiento de la endogeneidad en sistemas complejos.⁹ A diferencia de los métodos de máxima verosimilitud que requieren supuestos sobre la distribución de los errores, el GMM solo exige que se cumplan ciertas condiciones de momento u ortogonalidad entre los instrumentos y las perturbaciones.⁴

GMM frente a estimadores clásicos en presencia de heterocedasticidad

El GMM es intrínsecamente más flexible que el 3SLS cuando los datos presentan heterocedasticidad o autocorrelación, problemas comunes en las series de precios internacionales.¹⁰ El estimador GMM minimiza una forma cuadrática de las condiciones de momento utilizando una matriz de pesos óptima que, en su versión

robusta, tiene en cuenta la estructura de varianza de los errores.¹¹

En la práctica, la implementación de GMM para sistemas de ecuaciones grandes puede ser computacionalmente intensiva. Mientras que el 3SLS utiliza una solución de matriz cerrada rápida, el GMM requiere optimización numérica no lineal.¹¹ No obstante, estudios comparativos demuestran que el HCGMM (Heteroscedasticity-Consistent GMM) es el estimador más eficiente bajo violaciones severas de los supuestos clásicos, superando sistemáticamente al 2SLS y al 3SLS en términos de Error Cuadrático Medio (RMSE) y sesgo.¹⁰

Endogeneidad dinámica en datos de panel

El análisis de oferta y demanda global a menudo utiliza datos de panel para capturar la variación tanto temporal como entre países o regiones. Aquí surge el problema de la endogeneidad dinámica, donde los valores rezagados de la variable dependiente (por ejemplo, el consumo de energía del año pasado) afectan los valores actuales y están correlacionados con los efectos fijos no observados.⁹ Los modelos de GMM en Diferencias (Arellano-Bond) y GMM en Sistema (Blundell-Bond) se han vuelto herramientas indispensables para corregir este sesgo, permitiendo estimar la persistencia de la demanda global de materias primas con una precisión inalcanzable para los modelos estáticos.⁴

Dinámica de series temporales y transmisión de precios internacionales

La econometría de la oferta y demanda global no puede limitarse a instantáneas estáticas del equilibrio; debe capturar la evolución temporal de los

precios y las cantidades. Los modelos de Vectores Autorregresivos (VAR) y sus extensiones han revolucionado este campo al permitir que todas las variables del sistema sean tratadas como endógenas, capturando las retroalimentaciones entre ellas.¹²

Cointegración y modelos de corrección de errores (VECM)

Cuando se analizan mercados de productos básicos como el trigo, el petróleo o los metales, es crucial determinar si los precios en diferentes regiones geográficas están integrados. El concepto de cointegración, introducido por Engle y Granger y perfeccionado por Johansen, postula que si dos o más series de precios no estacionarias comparten una tendencia común a largo plazo, existe una relación de equilibrio estable entre ellas.¹⁴

Un Modelo de Corrección de Errores Vectoriales (VECM) permite descomponer la dinámica de los precios en dos componentes: el ajuste hacia el equilibrio de largo plazo y las desviaciones transitorias de corto plazo.¹⁴ Por ejemplo, en el mercado mundial del trigo, se ha observado que los precios domésticos en grandes productores como India están cointegrados con los precios de exportación de Estados Unidos y Argentina.^{14,15}

El enigma de la autocorrelación en modelos de almacenamiento

Un avance significativo en la econometría aplicada a commodities es la modelización del almacenamiento estratégico. Históricamente, los economistas enfrentaron el "rompecabezas de la autocorrelación": los precios de las materias primas muestran una persistencia mucho mayor de la que sugieren los choques de producción anuales.¹⁶ Modelos recientes de expectativas racionales con

almacenamiento han resuelto este dilema al demostrar que las decisiones de inventario actúan como un mecanismo de amortiguación.

Investigaciones de vanguardia indican que aproximadamente el 40% de la autocorrelación anual observada en los precios de los granos se explica por las decisiones de almacenamiento, que transfieren excedentes de periodos de abundancia a periodos de escasez.¹⁶ Además, estos modelos sugieren una asimetría crítica: mientras que el almacenamiento protege contra colapsos de precios ante choques de oferta positivos, los picos dramáticos de precios suelen ser causados por choques de demanda positivos masivos que agotan las existencias disponibles.¹⁶

Interdependencia global y el modelo Global VAR (GVAR)

En un mundo globalizado, los choques económicos ya no se limitan a fronteras nacionales. La crisis financiera de 2008 y la reciente crisis energética han subrayado la necesidad de marcos que capturen las interdependencias macroeconómicas y financieras a escala planetaria. El modelo GVAR (Global Vector Autoregression) es la respuesta metodológica a este desafío.¹⁷

Estructura y resolución de la dimensionalidad

El GVAR aborda la "maldición de la dimensionalidad" —la proliferación de parámetros que ocurre cuando se intenta incluir muchas variables de muchos países en un solo VAR— mediante un enfoque de dos etapas.¹⁷ Primero, se estiman modelos individuales para cada país (VARX*) que incluyen variables domésticas y variables externas ponderadas (variables "estrella"), como el PIB extranjero o la inflación global,

que actúan como proxies de factores globales comunes.¹⁷ Segundo, estos modelos individuales se combinan en un sistema global único que puede ser resuelto simultáneamente para todos los países.¹⁸

Dinámica de spillovers: El caso de China

El análisis de los efectos de desbordamiento de China ilustra la utilidad del GVAR. Al comparar los patrones comerciales de principios de los 2000 con los de 2020, los modelos GVAR revelan una transformación estructural en la vulnerabilidad global.²⁰ La participación de China en el comercio mundial ha pasado de niveles marginales a ser el principal socio para la mayoría de las economías.

Los resultados del GVAR indican que un choque negativo en el PIB de China tiene hoy un impacto tres veces mayor en el crecimiento de Estados Unidos y Europa que hace dos décadas.²⁰ Esto se debe no solo al volumen comercial, sino a la integración de China en los mercados financieros y su influencia en los precios globales de las materias primas, de las cuales es el principal consumidor.²⁰ El modelo GVAR permite a los bancos centrales realizar análisis de escenarios contrafactuales, evaluando, por ejemplo, el impacto de una guerra comercial o de una devaluación del yuan sobre las balanzas comerciales de terceros países.¹⁹

Modelos de Equilibrio General Dinámico Estocástico (DSGE) de economía abierta

Mientras que los modelos VAR son predominantemente empíricos y basados en datos, los modelos DSGE representan el núcleo de la teoría macroeconómica moderna, proporcionando microfundamentos sólidos basados en la optimización del

comportamiento de hogares y empresas.²²

El modelo SIGMA y la política monetaria global

El modelo SIGMA, desarrollado por la Reserva Federal de Estados Unidos, es un ejemplo prominente de un DSGE de economía abierta y multipaís diseñado para el análisis cuantitativo de políticas.²⁴ SIGMA incorpora fricciones nominales (precios y salarios rígidos) y reales (costes de ajuste en la inversión y el consumo) que permiten al modelo replicar la persistencia observada en los datos macroeconómicos.²⁵

Una característica distintiva de SIGMA es el tratamiento de las expectativas. A diferencia de los modelos de expectativas adaptativas tradicionales, SIGMA asume expectativas racionalmente consistentes con el modelo, pero introduce "fricciones de información".²⁵ Los agentes utilizan filtros de Kalman para distinguir entre choques permanentes y transitorios en la productividad o la política fiscal, lo que genera respuestas graduales y "hump-shaped" en el consumo y la inversión que se alinean con la evidencia empírica de los modelos VAR.²⁵

Identificación de choques en períodos de crisis

Durante la recuperación post-pandemia de 2021-2022, el marco DSGE se utilizó para discernir si la inflación era impulsada por un exceso de demanda o por restricciones de oferta.²⁶ Al modelar restricciones de capacidad de producción como cuellos de botella físicos, los analistas de la Fed pudieron demostrar que estas restricciones actuaban de manera similar a choques de "markup" o de empuje de costes, elevando las curvas de Phillips de precios domésticos e importados.²⁶ Las simulaciones indicaron que las restricciones vinculantes explicaron aproximadamente la mitad del aumento de la inflación en ese periodo, validando la narrativa de que la

demandas robustas chocan contra una oferta global inflexible.²⁶

Sin embargo, los modelos DSGE han sido objeto de intensas críticas por su incapacidad para predecir crisis sistémicas profundas, como la de 2008.²⁷ Muchos investigadores argumentan que la dependencia de linealizaciones alrededor del estado estacionario y la exclusión de fricciones financieras complejas limitan su utilidad como herramientas de alerta temprana.²² En respuesta, la nueva generación de modelos DSGE está integrando sectores financieros detallados y mecanismos de no linealidad para capturar mejor los riesgos de cola.²²

Heterogeneidad de agentes y modelos HANK

Uno de los avances más disruptivos en la econometría de la última década ha sido el paso de modelos con un "Agente Representativo" (RANK) a modelos con "Agentes Heterogéneos" (HANK).²⁹ Los modelos RANK asumen que todos los consumidores son iguales, lo que implica que responden de manera idéntica a los cambios en los tipos de interés o la política fiscal. HANK rompe este supuesto al incorporar una distribución realista de riqueza, ingresos y liquidez.³⁰

Transmisión de la demanda y Propensión Marginal al Consumo (MPC)

En los modelos HANK, la transmisión de la política económica ocurre de manera muy diferente. Mientras que en RANK el canal principal es la sustitución intertemporal (la gente ahorra más si los tipos suben), en HANK el canal dominante es el efecto de equilibrio general sobre los ingresos.³⁰

La evidencia empírica muestra que los hogares tienen una Propensión

Marginal al Consumo (MPC) agregada de entre el 15% y el 20% en el primer trimestre, comparado con el minúsculo 0.5% a 1% que predicen los modelos de agente representativo.³⁰ Esto se debe a la existencia de hogares "hand-to-mouth" (viven al día), que consumen inmediatamente cualquier incremento en sus ingresos líquidos. En consecuencia, los choques de demanda global tienen efectos multiplicadores mucho más potentes y persistentes en economías con alta desigualdad o restricciones de crédito.³⁰

Aplicación al mercado inmobiliario y alquileres

Investigaciones recientes utilizando modelos HANK han analizado la transmisión de la política monetaria a los mercados de vivienda.³² Al modelar la elección entre ser propietario o inquilino bajo restricciones de endeudamiento, se ha descubierto que una subida de tipos de interés genera una caída inmediata y profunda en los precios de las casas, pero mantiene los precios de los alquileres estables o incluso al alza a corto plazo.³² Los propietarios, enfrentados a mayores costes hipotecarios, intentan trasladar el coste a los inquilinos, pero la fricción en la búsqueda de vivienda y los contratos a largo plazo moderan esta transmisión, creando dinámicas de mercado divergentes que los modelos agregados no pueden capturar.³²

Frontera tecnológica: Machine Learning y Big Data en la economía global

La disponibilidad masiva de datos y el aumento del poder computacional han permitido la integración del aprendizaje automático (Machine Learning) en el arsenal econométrico tradicional. Estos métodos son particularmente eficaces para manejar no linealidades y conjuntos de datos de alta dimensionalidad que antes eran

inabarcables.³³

Nowcasting del comercio mundial con conjuntos de datos masivos

El comercio mundial es un indicador temprano crucial de la actividad económica, pero los datos oficiales suelen publicarse con retrasos de meses. Para obtener estimaciones en tiempo real (*nowcasting*), los economistas del BCE y otras instituciones han desarrollado enfoques de Machine Learning que procesan hasta 11,000 series de indicadores económicos.³⁵

Un enfoque secuencial de tres pasos ha demostrado ser superior a las técnicas tradicionales de OLS o modelos de factores dinámicos:

1. **Pre-selección:** Uso de algoritmos de penalización como Lasso o LARS para identificar los predictores más relevantes entre cientos de variables de alta frecuencia (PMI, datos de puertos, imágenes satelitales).³³
2. **Extracción de factores:** Aplicación de PCA para condensar la información seleccionada en unos pocos factores ortogonales que resumen el estado de la economía global.³³
3. **Regresión de Machine Learning:** Uso de *Macroeconomic Random Forest* (MRF) o Gradient Boosting para realizar la predicción final, capturando interacciones no lineales que surgen especialmente durante períodos de crisis.³³

Este enfoque ha demostrado que el Machine Learning es más efectivo cuando se utiliza como complemento de la estructura econométrica clásica (reduciendo el ruido primero mediante factores) en lugar de aplicarse directamente sobre los datos brutos.³³

Double Machine Learning (DML) para elasticidades de precio

La estimación de la elasticidad precio de la demanda es una tarea crítica pero difícil debido a la endogeneidad del precio. El *Double Machine Learning* (DML) aborda este problema combinando la potencia predictiva de algoritmos como XGBoost con la inferencia estadística robusta.⁷

El proceso de DML utiliza la "ortogonalización": se entrena un modelo de ML para predecir la cantidad demandada a partir de variables de confusión (clima, temporada, festivos, competidores) y otro modelo para predecir el precio a partir de las mismas variables.⁷ Al restar estas predicciones de los valores reales, se obtienen residuos que representan la variación en el precio y la cantidad que no puede ser explicada por factores externos. La elasticidad se estima finalmente mediante una regresión de los residuos de la cantidad sobre los residuos del precio, proporcionando una medida puramente causal del impacto del precio.⁷ Esta técnica ha revelado elasticidades mucho más precisas en sectores minoristas y de transporte, donde los precios cambian dinámicamente cada minuto.⁷

Casos de estudio sectoriales: Energía y minerales críticos

La aplicación de estas técnicas avanzadas es particularmente evidente en el análisis de los mercados de energía y de las materias primas necesarias para la transición energética.

El mercado petrolero: Agotamiento y elasticidad estructural

El Fondo Monetario Internacional (FMI) utiliza modelos estructurales

dinámicos para el mercado del crudo que integran factores geológicos y económicos.⁴⁰

La oferta de petróleo se modela considerando el agotamiento natural de los campos convencionales (estimado en 3-4% anual) y la exploración endógena que responde a los precios.⁴⁰

El modelo estructural revela una dualidad en la oferta: mientras que la producción de petróleo convencional es muy inelástica en el corto plazo debido a los largos tiempos de inversión, la producción de *shale oil* es extremadamente sensible a los precios, actuando como un equilibrador del mercado global.⁴⁰ En el lado de la demanda, el crecimiento secular de las economías emergentes (China e India) sigue compensando las ganancias de eficiencia energética en los países de la OCDE, manteniendo una presión alcista sobre el equilibrio de largo plazo.⁴¹

La econometría de los minerales críticos (Litio, Cobre, Níquel)

La transición hacia vehículos eléctricos y energías renovables ha disparado la demanda de minerales estratégicos. La Agencia Internacional de la Energía (IEA) y el USGS emplean modelos de ecuaciones simultáneas para estimar la disponibilidad de estos recursos en el horizonte 2024-2040.⁴³

Un hallazgo econométrico clave, utilizando 2SLS, es que la demanda de litio se ha vuelto significativamente menos elástica (-0.11) desde 2020.⁴⁵ Esto indica que los fabricantes de baterías están dispuestos a aceptar precios mucho más altos para asegurar el suministro físico, lo que aumenta el riesgo de volatilidad extrema. El mercado del litio, en particular, enfrenta un "gran desconecte": mientras que la demanda proyectada crecerá 3.5 veces para 2030, la oferta minera tarda entre 5 y 25 años en entrar en operación, creando cuellos de botella estructurales.⁴⁶

La concentración geográfica de la oferta —con China procesando el 65% del litio y el 85% de las tierras raras— introduce riesgos geopolíticos que los modelos econométricos ahora integran mediante variables de "riesgo de país" y simulaciones de interrupción de suministros.⁴³ El uso de GMM en estos contextos permite estimar la sensibilidad de la transición energética global ante choques en los costes de capital o cambios en las políticas de subsidios (como el Inflation Reduction Act en EE. UU.).⁴⁸

Spillovers de mercados emergentes y política comercial

El informe de perspectivas mundiales (WEO) del FMI ha documentado un cambio fundamental en el origen de los choques económicos. Los mercados emergentes del G20 (EM G20) ya no son solo receptores de choques de las economías avanzadas; se han convertido en motores de propagación global.⁵⁰

Modelos de gravedad y sorpresas de crecimiento

Utilizando modelos de gravedad estándar para datos de comercio bilateral, el FMI ha cuantificado que la integración comercial de los EM G20 se ha acelerado drásticamente en la última década, incluso si se excluye a China del análisis.⁵¹ La correlación entre las "sorpresa de crecimiento" (la diferencia entre el crecimiento real y el proyectado) de los emergentes y las economías avanzadas se ha vuelto estadísticamente significativa desde 2014.⁵¹

El análisis VAR estructural estima que un choque de crecimiento en los EM G20 explica ahora el 5% de la fluctuación del PIB en las economías avanzadas, lo cual es masivo considerando que hace dos décadas este impacto era casi nulo.⁵¹ Canales

como los precios de las materias primas y la integración financiera a través de los tipos de interés globales son los principales conductores de estos efectos de desbordamiento.⁵¹

El auge del proteccionismo comercial

Desde 2019, la econometría de la oferta y la demanda global ha tenido que incorporar una nueva variable: la explosión en el uso de políticas comerciales distorsivas.⁵² Utilizando modelos de factores dinámicos sobre bases de datos de gran escala (como GTA y TMDB), los investigadores han documentado un giro estructural hacia el nacionalismo económico.⁵² Estas políticas, a menudo justificadas por la seguridad nacional o la autonomía estratégica en minerales críticos, desplazan las curvas de oferta global hacia la izquierda y aumentan la rigidez de los precios, lo que complica la tarea de los bancos centrales para controlar la inflación sin generar recesiones.⁵⁰

Modelización de constructos latentes en el comercio internacional

En síntesis, un área en expansión es el uso de Modelos de Ecuaciones Estructurales (SEM) con variables latentes.⁵³ Muchos de los factores que impulsan la oferta y la demanda global no son directamente observables, como la "incertidumbre política", la "confianza del consumidor" o la "resiliencia de la cadena de suministro".⁵³

54

Integración de análisis de factores y diagramas de ruta

El SEM con variables latentes combina el análisis de factores —que permite

inferir un constructo oculto a partir de indicadores observables (por ejemplo, inferir la "resiliencia económica" a partir de la volatilidad del PIB y los déficits fiscales) — con el análisis de rutas causales.⁵⁴ Esto permite a los economistas purgar los errores de medición de las variables explicativas, algo que los modelos de regresión estándar no pueden hacer.⁵⁵

En el ámbito del comercio internacional, el SEM se utiliza para validar teorías sobre cómo la inversión en infraestructura (observable) mejora la productividad (latente) y, a su vez, impulsa las exportaciones.⁵⁴ Las metodologías más recientes permiten integrar variables latentes con modelos de compuestos, utilizando estimadores de máxima verosimilitud que manejan datos faltantes de manera eficiente, lo que es vital cuando se trabaja con países en desarrollo que tienen estadísticas incompletas.⁵⁵

Conclusiones sobre la frontera econométrica global

El análisis avanzado de la oferta y la demanda global ha trascendido la búsqueda de coeficientes estáticos para convertirse en una disciplina que modela sistemas dinámicos, heterogéneos y altamente interconectados. La integración de los modelos estructurales clásicos (SEM) con las innovaciones del aprendizaje automático (Double ML) y la microfundamentación detallada (HANK) permite una comprensión mucho más profunda de los mecanismos de mercado.

Las principales lecciones de la literatura contemporánea sugieren que:

1. La simultaneidad es la norma, no la excepción, requiriendo el uso sistemático de estimadores de sistemas como 3SLS y GMM robustos para evitar sesgos de

política.

2. La dinámica del almacenamiento y la cointegración son fundamentales para entender la persistencia de los precios en los mercados de commodities, donde los choques de demanda positivos son los principales responsables de las crisis de precios.
3. El mapa de spillovers globales se ha redibujado; la salud económica de los mercados emergentes del G20 es ahora tan crítica para la estabilidad global como la de las potencias tradicionales.
4. La tecnología de Big Data y Nowcasting es la única herramienta capaz de proporcionar la agilidad necesaria para la toma de decisiones en tiempo real ante choques sistémicos de gran escala.

En un entorno marcado por la fragmentación comercial y la transición energética acelerada, la econometría avanzada no es solo una herramienta académica, sino un componente esencial de la infraestructura de seguridad económica global. La capacidad de predecir cómo se ajustarán los mercados ante restricciones de capacidad física, cambios en la distribución de la riqueza o nuevas barreras comerciales definirá el éxito de las políticas macroeconómicas en la próxima década.

Capítulo II

Hacia una Nueva Gobernanza Económica Basada en Datos

La metamorfosis de la economía global en el siglo XXI no se limita a una simple digitalización de procesos analógicos, sino que representa una reorganización basal de la lógica de producción, el intercambio y la toma de decisiones impulsada por la inteligencia artificial y el procesamiento masivo de información.¹ Esta transición hacia una gobernanza económica basada en datos implica el despliegue de tecnologías donde las máquinas ejecutan funciones cognitivas tradicionalmente humanas —como aprender, analizar y resolver problemas complejos— para optimizar la política pública y la eficiencia de los mercados.¹ En este contexto, la información extraída de las interacciones sociales y de objetos interconectados genera beneficios económicos sustanciales, pero también exige un giro estructural en la forma en que el Estado y la sociedad interactúan.¹

El Cambio de Paradigma: Los Datos como Activo Estratégico

La gobernanza económica moderna se fundamenta en el reconocimiento de los datos como un activo estratégico indispensable para la competitividad y el bienestar social.³ A diferencia de los modelos tradicionales de administración, la gobernanza basada en datos permite transitar de un modelo reactivo a uno predictivo, donde el Estado es capaz de anticipar las necesidades de la ciudadanía y simplificar su relación con los usuarios eliminando barreras burocráticas innecesarias.² La implementación

de un gobierno digital eficaz requiere, por tanto, una arquitectura que integre la institucionalidad, un marco jurídico sólido, infraestructura tecnológica de vanguardia y una formación continua en capacidades digitales.²

La inteligencia artificial se percibe hoy como el mayor catalizador de oportunidad comercial en la economía global, con un impacto comparable al descubrimiento de la electricidad durante la Segunda Revolución Industrial.⁵ Como nuevo factor de producción que trasciende al capital y al trabajo, la IA tiene el potencial de agregar hasta 4.4 billones de dólares anuales a la economía mundial, permitiendo ahorros de tiempo de hasta el 70\% para los trabajadores mediante la automatización inteligente y la optimización de procesos complejos.⁵ No obstante, este potencial económico debe gestionarse con cautela para garantizar que promueva un desarrollo integrador y participativo, evitando que el ciberespacio se convierta en un campo de batalla o en una herramienta de exclusión.¹

Marcos Internacionales y el Contrato Social para los Datos

Para que la economía de los datos florezca de manera equitativa, es fundamental establecer un marco de gobernanza que aplique los principios de confianza, valor y equidad.⁶ El Banco Mundial propone que la gobernanza de datos debe entenderse como un contrato social donde el desarrollo de la infraestructura asegure que tanto las personas como los países más pobres tengan acceso asequible a los servicios digitales.⁶ Actualmente, se estima que los países de ingresos bajos están solo a un 30\% del camino hacia la implementación de buenas prácticas de gobernanza, mientras que los países de ingresos altos alcanzan un 50\%, lo que

evidencia una brecha significativa en la capacidad institucional para capturar el valor de la información.⁶

Recomendaciones de la OCDE y la Unión Europea

La Organización para la Cooperación y el Desarrollo Económicos (OCDE) enfatiza que los gobiernos deben tratar los datos como activos estratégicos, definiendo su valor y midiendo su impacto de forma constante.³ Los beneficios sociales y económicos del intercambio de datos en los sectores público y privado se estiman entre el 1\% y el 2.5\% del Producto Bruto Interno (PBI), aunque estos niveles no se han alcanzado plenamente debido a la desconfianza y los conflictos de interés entre los distintos actores.³ Las recomendaciones internacionales instan a los gobiernos a:

- Reforzar la confianza en todo el ecosistema de datos mediante la protección de la privacidad y la propiedad intelectual.³
- Estimular la inversión y el intercambio de información a través de incentivos claros.³
- Fomentar el uso responsable y transfronterizo de los datos para abordar desafíos globales como el cambio climático o las crisis sanitarias.³

En la Unión Europea, el Reglamento de Gobernanza de Datos (Data Governance Act) busca aumentar la disponibilidad de datos facilitando su reutilización en sectores estratégicos como la salud, el medio ambiente, la energía y las finanzas.⁷ Este marco legal fomenta el desarrollo de Espacios Comunes de Datos Europeos, donde intermediarios confiables aseguran que la información se comparta de acuerdo con los valores de la Unión, promoviendo la innovación y la creación de empleo.⁷ La normativa introduce también el "altruismo de datos", permitiendo que ciudadanos y empresas compartan su información de manera voluntaria para fines de

interés público, como la investigación médica de enfermedades raras.⁹

La Estrategia de Transformación Digital del Perú al 2030

El Perú ha emprendido un proceso decidido de transformación digital alineado con sus aspiraciones de adhesión a la OCDE.¹⁰ La Política Nacional de Transformación Digital al 2030 (PNTD) es el instrumento rector que define los lineamientos para alcanzar una ciudadanía digital plena, donde las personas puedan ejercer sus derechos y deberes en un entorno seguro y de calidad.¹² Esta política se articula sobre seis objetivos prioritarios que buscan impactar directamente en la productividad y la equidad social del país.¹²

El Perú ha logrado avances notables en el índice de desarrollo de gobierno electrónico (EGDI) de las Naciones Unidas, alcanzando en 2024 una puntuación de 0.807, situándose en el grupo de "muy alto nivel de desempeño" y ocupando el puesto 5 a nivel de América Latina y el Caribe.¹⁴ Este progreso refleja la madurez de la gobernanza digital, con un 100% de cumplimiento en la designación de oficiales de seguridad y confianza digital en los ministerios, y una creciente interoperabilidad a través del Sistema Nacional de Transformación Digital.¹¹

El Rol de la Secretaría de Gobierno y Transformación Digital

Bajo el liderazgo de la Presidencia del Consejo de Ministros (PCM) y la Secretaría de Gobierno y Transformación Digital (SGTD), se han desplegado servicios críticos como la plataforma Facilita Perú, que ha digitalizado más de 10,859 trámites desde 2020, facilitando la interacción ciudadana con las entidades del Estado.¹⁴ El

modelo peruano entiende la transformación digital como un cambio cultural disruptivo que utiliza el análisis de datos para generar valor económico y social.¹³ Un indicador clave de esta estrategia es el aumento de la capacidad digital de la población: mientras que en 2020 la ciudadanía ejercía menos de dos de las ocho capacidades digitales reconocidas, la meta para el 2030 es que cada ciudadano ejerza al menos cuatro, lo que implica un salto cuantitativo en la inclusión digital activa.¹³

Gobernanza Fiscal y Aduanera Inteligente: El Caso de la SUNAT

La administración tributaria representa uno de los campos de aplicación más avanzados de la analítica de datos en el Perú. La Superintendencia Nacional de Aduanas y de Administración Tributaria (SUNAT) ha integrado el uso masivo de datos e inteligencia artificial en su Plan Estratégico Institucional 2024-2028 para combatir la evasión y la elusión fiscal de manera más eficiente.¹⁵ La estrategia se orienta al cierre de brechas de cumplimiento, contribuyendo a la sostenibilidad fiscal y la competitividad del país.¹⁵

El Arsenal Digital de la SUNAT y la Fiscalización Predictiva

La SUNAT ha desplegado herramientas tecnológicas diseñadas para hacer la fiscalización más precisa y menos intrusiva para el contribuyente cumplidor.¹⁸ Mediante el uso de Big Data, la institución realiza cruces de información que permiten detectar incrementos patrimoniales no justificados, gestionando más de 45 millones de transacciones virtuales solo en 2023.¹⁸ La implementación de la asistente virtual "SOFIA" permite una atención masiva las 24 horas, mientras que el análisis predictivo ayuda a identificar patrones de riesgo antes de que se consume el incumplimiento.¹⁸

Las acciones estratégicas de la SUNAT incluyen:

- Mejorar los medios de detección de la informalidad (ingresos no declarados) mediante el uso intensivo de IA.¹⁷
- Facilitar el cumplimiento voluntario a través de borradores de declaraciones prellenadas, lo que reduce errores y tiempos de gestión.¹⁸
- Fortalecer la capacidad de respuesta ante cambios en las modalidades de evasión, adaptando los servicios a la conectividad móvil.¹⁷

Comparativa Internacional en Recaudación y Big Data

A nivel global, la tendencia hacia la fiscalización inteligente es imparable. En España, la Agencia Tributaria (AEAT) utiliza el análisis masivo de datos para controlar a los grandes patrimonios "deslocalizados" que simulan residencia en el extranjero.¹⁹ De manera similar, en Brasil, la Receita Federal ha evolucionado su ecosistema de datos desde un almacén de datos corporativo en 2001 hacia un complejo "data lake" que integra cientos de sistemas transaccionales para optimizar la inspección y la recaudación.²⁰

Innovación Monetaria y el Proyecto de CBDC del BCRP

El Banco Central de Reserva del Perú (BCRP) se encuentra en la vanguardia de la innovación financiera con el desarrollo de una Moneda Digital de Banco Central (CBDC por sus siglas en inglés).²² El objetivo principal de este proyecto no es reemplazar al efectivo ni competir con los pagos digitales existentes, sino expandir el acceso a la población no bancarizada y reducir los altos costos del manejo de efectivo

en una economía con alta informalidad.²²

Pilotos de Dinero Digital y Resultados Regionales

El BCRP ha iniciado la fase de evaluación de sus pilotos de innovación con dinero digital, destacando el notable crecimiento de usuarios activos y la transaccionalidad a nivel nacional.²³ En colaboración con empresas tecnológicas como Bitel, el primer piloto ha permitido que el número de usuarios crezca de 805,000 a 2.5 millones entre octubre de 2024 y abril de 2025.²⁴ Un hallazgo fundamental es que en las ocho regiones con menores niveles de inclusión financiera, el crecimiento de usuarios fue del 229\%, demostrando que la tecnología digital puede romper las barreras geográficas del sistema bancario tradicional.²⁴

La implementación de la CBDC busca garantizar:

1. **Pagos inmediatos e irrevocables:** Especialmente para transacciones de menor monto que hoy dependen exclusivamente del efectivo.²²
2. **Inclusión financiera rural:** Al utilizar infraestructuras de telecomunicaciones, se permite llegar a zonas donde no existen sucursales bancarias, como Puno o Madre de Dios, donde la inclusión financiera apenas ronda el 30\%.²⁴
3. **Reducción de riesgos:** El modelo híbrido adoptado permite que el banco central mantenga el control sobre los saldos mientras las entidades privadas gestionan la interfaz con el cliente, minimizando los riesgos de desintermediación financiera.²⁴

Interoperabilidad: La Clave del Flujo de Datos en el Estado

La gobernanza económica basada en datos requiere que las instituciones estatales no operen como silos aislados, sino como un sistema integrado. La interoperabilidad es la capacidad de las organizaciones para intercambiar información y conocimiento de manera eficiente a través de sus procesos de negocio y el intercambio de datos entre sus sistemas de TI.²⁵

El Benchmarking de Estonia y el Sistema X-Road

Estonia es el referente mundial de este modelo gracias a X-Road, una plataforma descentralizada que permite el intercambio seguro de datos entre el sector público y el privado.²⁷ Este sistema ha permitido que el 99\% de los servicios estatales sean digitales, incluyendo el voto electrónico y la creación de empresas en menos de 15 minutos.²⁹ El éxito de Estonia radica en principios arquitectónicos como el "once-only" (una sola vez), que obliga al Estado a no pedir al ciudadano información que ya reside en alguna base de datos gubernamental.²⁹

El impacto económico de X-Road es tangible: se estima que cada año ahorra a la población estonia una cantidad de tiempo equivalente a 1.48 millones de horas mensuales, lo que representa un multiplicador de la productividad nacional.²⁸ Además, el sistema garantiza la soberanía del dato, permitiendo que los ciudadanos vean en tiempo real quién ha consultado su información personal, fortaleciendo la confianza en las instituciones.²⁸

La Plataforma de Interoperabilidad del Estado (PIDE) en Perú

En el Perú, la Plataforma de Interoperabilidad del Estado (PIDE), gestionada por la Secretaría de Gobierno y Transformación Digital de la PCM, es la herramienta que facilita la simplificación administrativa y la reutilización de datos entre más de

450 entidades.²⁶ Al no almacenar datos, la PIDE actúa como un puente seguro que reduce costos operativos y evita que el ciudadano deba presentar documentos que el Estado ya posee.²⁶ El fortalecimiento de la PIDE es fundamental para alcanzar las metas de la Política Nacional de Competitividad y Productividad, orientando los recursos hacia una asignación más eficiente.³¹

Desafíos Estructurales: Informalidad y Brecha Regional

A pesar de los avances tecnológicos, la gobernanza económica en el Perú enfrenta el reto persistente de la informalidad, que se sitúa por encima del 70\% a nivel nacional.³² La informalidad no es solo una evasión de impuestos, sino una respuesta distorsionada de la economía ante un marco normativo agobiante y servicios públicos ineficientes.³² Esta situación genera un círculo vicioso: las empresas informales se mantienen pequeñas para evitar el control, lo que limita su productividad y su capacidad de acceso al crédito formal.³²

El Impacto de la Informalidad en la Productividad

La evidencia sugiere que la informalidad induce a una asignación deficiente de recursos, congestionando la infraestructura pública sin contribuir a su financiamiento.³² Existe una correlación directa entre la pobreza monetaria y la informalidad laboral; regiones como Puno, Pasco y Huancavelica presentan índices de pobreza superiores al 40\%, coincidiendo con las tasas más altas de empleo informal.³⁴ En contraste, Lima Metropolitana concentra el 42.8\% del PBI nacional y el 59.4\% del aparato industrial, lo que evidencia un proceso centralizador que la digitalización aún no ha logrado revertir totalmente.³⁴

La Digitalización como Motor de Formalización

El Ceplan identifica el avance de la digitalización del Estado como una oportunidad estratégica para impulsar la formalización laboral y productiva regional.³³ El desarrollo de plataformas digitales y servicios en línea reduce las barreras burocráticas y los costos de entrada a la formalidad, permitiendo que más trabajadores accedan a derechos como salud y pensiones.³³ La formalización no solo eleva el bienestar individual, sino que fortalece la recaudación fiscal y permite al Estado ofrecer mejores servicios públicos, cerrando el círculo de la productividad.³³

Tecnologías de Vanguardia: Blockchain, IoT y Gestión de Crisis

La nueva gobernanza económica también se nutre de tecnologías emergentes que garantizan la integridad de los datos en entornos descentralizados. El Blockchain, el Internet de las Cosas (IoT) y la IA son los pilares de la transición hacia un "gobierno inteligente" capaz de proveer servicios personalizados y confiables.³⁵

Blockchain y la Seguridad del Dato

El Blockchain ofrece una solución transformadora para los desafíos de seguridad y escalabilidad del IoT, permitiendo la comunicación segura entre miles de millones de dispositivos sin necesidad de una autoridad central.³⁷ En el ámbito gubernamental, el uso de blockchain puede agilizar los procesos burocráticos y hacerlos más seguros, facilitando la sincronización de datos entre diferentes departamentos estatales.³⁶ La transparencia y la inmutabilidad de los registros en blockchain son críticas para áreas como la gestión de la cadena de suministro, la salud

y las ciudades inteligentes.³⁷

Lecciones de la Gestión de Crisis (COVID-19)

La pandemia del COVID-19 actuó como un catalizador forzoso para la gobernanza de datos. Los países que contaban con infraestructuras digitales más robustas pudieron implementar respuestas fiscales y sanitarias más efectivas.³⁸ El uso de analítica avanzada permitió a ciudades en el mundo cuantificar costos de iniciativas de emergencia y guiar recursos escasos hacia las áreas de mayor necesidad en tiempo real.³⁹ En el Perú, la pandemia impulsó la adopción de pagos digitales en programas sociales para fortalecer la entrega de apoyos económicos a la población más vulnerable.¹⁰

Ética, Privacidad y Soberanía Digital

El tránsito hacia una economía basada en datos no está exento de riesgos éticos profundos. El inmenso poder que otorga el control de la información puede derivar en una "colonización digital", donde grandes plataformas tecnológicas extraen y analizan datos de usuarios locales con un beneficio nominal para los generadores de la información.⁵ La gobernanza debe, por tanto, equilibrar la innovación con la protección de la intimidad y la autonomía personal.⁴⁰

Desafíos Éticos y Sesgos Algorítmicos

Uno de los principales temores en el uso de la IA para la política pública es la discriminación algorítmica. Los sesgos en los datos o en el diseño de los modelos pueden producir resultados injustos, discriminando a grupos poblacionales específicos o privilegiando arbitrariamente a otros.⁵ Para mitigar estos riesgos, es

imperativo:

- Exigir transparencia en los algoritmos de toma de decisiones.⁴⁰
- Establecer límites éticos al uso preventivo de la información para evitar la manipulación psicológica o política.⁴⁰
- Garantizar que la tecnología se diseñe bajo principios de sostenibilidad y equidad, incorporando el bienestar de las generaciones futuras.⁴⁰

Ciberseguridad y Protección de Datos Personales

La ciberseguridad debe ser el pilar de la privacidad moderna. Ante la convergencia de tecnologías operacionales e informáticas, las infraestructuras críticas son cada vez más vulnerables a ataques masivos de datos sensibles.⁴² El enfoque de "privacidad por diseño" es esencial para asegurar que las nuevas tecnologías nazcan protegidas y que el Estado mantenga la soberanía sobre sus infraestructuras de datos.²⁸ En el Perú, la Ley de Protección de Datos Personales y el Centro Nacional de Seguridad Digital son las herramientas que buscan mitigar estas amenazas en el entorno digital.¹⁴

Hacia una Síntesis de la Nueva Gobernanza Económica

La construcción de una nueva gobernanza económica basada en datos es un imperativo para la competitividad del Perú y del mundo en la era de la inteligencia artificial. Esta transición requiere no solo de cables y servidores, sino de un nuevo contrato social donde el dato se entienda como un bien público que genera valor, confianza y equidad.¹

La experiencia internacional muestra que el éxito radica en la interoperabilidad, la transparencia y la formación de talento digital.¹² En el caso peruano, la Política Nacional de Transformación Digital al 2030 marca una ruta clara para integrar la economía informal, modernizar la administración tributaria y democratizar el acceso al sistema financiero mediante la innovación monetaria del BCRP.¹² El reto final consiste en asegurar que esta revolución digital no amplifique las desigualdades existentes, sino que sirva como el motor definitivo para un desarrollo inclusivo y sostenible en todas las regiones del país. La gobernanza de datos es, en última instancia, la gestión de la inteligencia colectiva de una nación para el bienestar de todos sus ciudadanos.

Capítulo III

Integración de la Inteligencia Artificial en la Previsión de Flujos Comerciales: Transformación de la Macroeconómica Global y Operativa (2025-2040)

La economía global atraviesa un periodo de volatilidad estructural donde la previsibilidad de los flujos comerciales se ha convertido en el activo estratégico más valioso para gobiernos, instituciones financieras y empresas multinacionales. En 2025, la integración de la inteligencia artificial (IA) en la previsión de flujos comerciales ha dejado de ser una innovación periférica para constituirse en el núcleo de la resiliencia económica. Este fenómeno no solo responde a la necesidad de gestionar datos masivos, sino también a la imperativa de navegar un entorno caracterizado por tensiones geopolíticas crecientes, reordenamientos de prioridades políticas y una digitalización acelerada de los servicios. La evidencia recopilada en informes de la Organización Mundial del Comercio (OMC), el Fondo Monetario Internacional (FMI) y el Banco Mundial sugiere que la IA tiene el potencial de incrementar el comercio mundial entre un 34% y un 37% para el año 2040, impulsando simultáneamente un crecimiento del Producto Interno Bruto (PIB) global de hasta el 13%.¹

Dinámicas Macroeconómicas y el Papel de la Inteligencia Artificial en 2025

El año 2025 se define por una "resiliencia tenue" en medio de una

incertidumbre persistente.⁴ Con un crecimiento global proyectado en el 3.2%, la economía mundial se enfrenta a vientos en contra derivados de la fragmentación geoeconómica y la aplicación de aranceles masivos que han alcanzado niveles no vistos en un siglo.⁵ En este contexto, la IA actúa como un amortiguador de choques externos, permitiendo a los actores económicos anticipar distorsiones en las cadenas de suministro y optimizar la asignación de recursos. Las empresas han comenzado a utilizar modelos predictivos para el "front-loading" o adelanto de importaciones ante la inminencia de cambios en la política arancelaria, redirigiendo flujos comerciales hacia terceros países para mitigar el impacto de las barreras comerciales.⁶

La inversión en tecnología de IA ha seguido un patrón comparable al auge de Internet en la década de 1990, con valoraciones de mercado en aumento y una fuerte inversión en propiedad intelectual y equipos.⁶ No obstante, el FMI advierte sobre el riesgo de una mala asignación de recursos si los subsidios en sectores estratégicos, como los vehículos eléctricos y los paneles solares, no se acompañan de ganancias de productividad agregadas.⁷ La IA se posiciona como la herramienta clave para corregir estas ineficiencias, facilitando una "globalización de precisión" donde los flujos comerciales se optimizan mediante el análisis en tiempo real de variables exógenas y endógenas.

El impacto de la IA es particularmente notable en el comercio de servicios prestados digitalmente. Mientras que el sector manufacturero espera un crecimiento impulsado por la IA de entre el 22% y el 24%, los servicios digitales podrían experimentar una expansión de hasta el 42%.² Esta disparidad refleja la alta comerciabilidad de los servicios de IA y la reducción de los costos operativos transfronterizos que esta tecnología facilita.

Arquitecturas de Aprendizaje Profundo para la Previsión de Series Temporales

La previsión de flujos comerciales depende de la capacidad de los modelos para interpretar datos secuenciales complejos. Las técnicas tradicionales de econometría, como los modelos ARIMA, han sido superadas por arquitecturas de aprendizaje profundo que manejan relaciones no lineales y dependencias a largo plazo de manera más robusta.⁸

Redes Recurrentes: LSTM y GRU

Las redes de Memoria a Largo Plazo (LSTM) y las Unidades Recurrentes Gated (GRU) son fundamentales en el análisis de series temporales financieras y comerciales. La arquitectura LSTM utiliza un mecanismo de compuertas para regular el flujo de información, lo que permite que el modelo retenga información relevante de períodos pasados sin sufrir el problema del gradiente desvanecido que afectaba a las redes neuronales recurrentes (RNN) estándar.⁹

El proceso de una celda LSTM se rige por las siguientes ecuaciones matemáticas que definen sus compuertas:

1. Compuerta de Olvido (Forget Gate): Determina qué información del estado de la celda anterior debe descartarse.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

¹¹

2. Compuerta de Entrada (Input Gate): Decide qué nueva información se almacenará en el estado de la celda.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

11

3. Estado de la Celda Candidato: Crea un vector de nuevos valores potenciales que podrían añadirse al estado.

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

11

4. Actualización del Estado de la Celda: Combina la información filtrada del pasado con los nuevos datos.

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

11

5. Compuerta de Salida (Output Gate): Define qué parte del estado de la celda se enviará como salida.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

11

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

11

Por su parte, el modelo GRU ofrece una alternativa más eficiente al combinar las compuertas de entrada y olvido en una sola compuerta de actualización, reduciendo el número de parámetros y el tiempo de entrenamiento sin sacrificar significativamente la precisión en contextos de alta frecuencia.¹⁰ En comparaciones experimentales, el modelo GRU ha demostrado un rendimiento superior en la

predicción de tasas de cambio de divisas y flujos de caja a corto plazo debido a su estructura simplificada.¹²

Transformers y Modelado de Largo Alcance

La introducción de la arquitectura Transformer ha revolucionado la previsión comercial al permitir el procesamiento paralelo de secuencias de datos y el uso de mecanismos de auto-atención.¹⁰ A diferencia de las RNN, que procesan los datos paso a paso, los Transformers consideran la relación entre todos los puntos de la secuencia simultáneamente, lo que los hace excepcionalmente aptos para capturar patrones estacionales y tendencias de largo plazo en el comercio internacional.¹⁰

Marcos avanzados como el *Temporal Fusion Transformer* (TFT) integran múltiples tipos de entrada, incluyendo metadatos estáticos, variables futuras conocidas (como calendarios de aranceles o festivos) y variables observadas en el pasado.¹² El TFT ha demostrado alcanzar resultados de vanguardia al proporcionar interpretabilidad sobre qué variables (como el sentimiento de noticias o precios de materias primas) influyen más en el pronóstico final.¹⁴ Además, nuevos modelos como *FutureTST* utilizan atención cruzada para integrar la influencia de variables exógenas futuras conocidas, mejorando la precisión de las predicciones endógenas en sistemas económicos reales.¹⁶

El Ecosistema de Datos Alternativos en el Comercio Exterior

La precisión de los modelos de IA en 2025 depende fundamentalmente de la calidad y diversidad de los datos. El concepto de "datos alternativos" se ha

consolidado como un pilar para obtener ventajas competitivas, proporcionando información en tiempo real que las estadísticas oficiales suelen reportar con meses de retraso.¹⁷

Imágenes Satelitales e Inteligencia Geoespacial

El uso de imágenes satelitales permite un monitoreo objetivo y continuo de la actividad física global. Los analistas financieros y los gestores de cadenas de suministro utilizan estas imágenes para evaluar la congestión en puertos marítimos, la ocupación de centros logísticos y los niveles de inventario en patios industriales.¹⁹

Un estudio técnico reciente de 2024 describe un sistema que utiliza redes neuronales convolucionales (CNN) para analizar las sombras proyectadas por los contenedores en las terminales portuarias. Este método permite estimar de forma dinámica el número de contenedores apilados verticalmente y el nivel de congestión del patio sin necesidad de información estadística interna de la terminal.²¹ Al integrar estos datos con el Sistema de Identificación Automática (AIS) de los buques, los modelos pueden predecir con una precisión del 96% las variaciones en los índices de flete de contenedores, como el SCFI de Shanghái.²³

El Papel de la Inteligencia de Documentos y el Procesamiento de Lenguaje Natural (NLP)

El comercio internacional sigue siendo una actividad intensiva en documentos. Sin embargo, la integración de la IA generativa y los modelos de lenguaje (LLM) está transformando el papeleo en flujos de datos estructurados. Los sistemas de Procesamiento Inteligente de Documentos (IDP) utilizan OCR avanzado para extraer datos de facturas comerciales, listas de empaque y certificados de origen con

una mínima intervención humana.²⁴

Plataformas como *iCustoms* han demostrado que la IA puede automatizar la clasificación de códigos del Sistema Armonizado (HS), sugiriendo códigos basados en descripciones de productos y aprendiendo de las correcciones de los expertos humanos para mejorar su precisión futura.²⁵ Esta automatización no solo acelera el despacho de aduanas, sino que alimenta los modelos de previsión de flujos con datos más precisos y granulares sobre las mercancías que cruzan las fronteras.

Inteligencia Artificial en las Finanzas Comerciales y Fintech

El financiamiento del comercio es el lubricante de la economía global, pero enfrenta una brecha de financiamiento de más de 2.5 billones de dólares, afectando desproporcionadamente a las PYMES en mercados emergentes.²⁷ Las empresas de tecnología financiera (fintech) están utilizando la IA para cerrar esta brecha mediante modelos de riesgo más inclusivos y procesos automatizados.

Modelos de Calificación Crediticia Basados en IA

Tradicionalmente, la calificación crediticia dependía de historiales financieros estáticos. Los sistemas modernos de IA aprovechan una gama mucho más amplia de datos, incluyendo la actividad en redes sociales, comportamiento de pago de servicios públicos y patrones de flujo de caja en tiempo real.²⁷ Esto permite a instituciones como HSBC y Citibank, así como a fintechs como Kabbage y Tala, realizar evaluaciones de riesgo más precisas para empresas que carecen de un historial crediticio extenso.²⁶

La integración de la IA con la tecnología blockchain y los contratos inteligentes

permite una automatización completa de los acuerdos de financiación comercial. En estos sistemas, la IA valida los documentos comerciales y el cumplimiento de los hitos logísticos, tras lo cual el contrato inteligente ejecuta el pago de forma inmutable.²⁶ Plataformas colaborativas como *Surecomp RIVO* conectan a proveedores, fabricantes y bancos en un ecosistema digital que utiliza API abiertas para facilitar la transparencia y la velocidad en la aprobación de créditos.²⁷

Iniciativas de Interoperabilidad Transfronteriza: Proyecto Aperta

Un hito fundamental en la integración financiera global es el **Proyecto Aperta**, lanzado por el Hub de Innovación del BIS en colaboración con bancos centrales de los Emiratos Árabes Unidos, Brasil, el Reino Unido y Hong Kong.³² Aperta es un prototipo de red de interoperabilidad multilateral que permite la portabilidad de datos financieros de forma segura y cifrada a través de API. El objetivo es permitir que una empresa en una jurisdicción comparta sus datos de facturación, cartas de crédito o conocimientos de embarque electrónicos con una institución financiera en otro país de forma instantánea. Esta eliminación de la fricción de datos permite la creación de "pasaportes de crédito" transfronterizos, facilitando que las PYMES accedan a financiamiento internacional de manera significativamente más rápida y económica.³⁰

Optimización Operativa y Resiliencia en la Cadena de Suministro

En la fase operativa, la IA ha pasado de ser una herramienta de soporte a ser el motor que orquesta los procesos logísticos de extremo a extremo. En 2025, el éxito de los equipos logísticos se mide por su capacidad para reducir el ruido de los datos

y comprimir los ciclos de decisión.³⁴

Previsión de la Demanda y Gestión de Inventarios

Las empresas más exitosas han refinado sus pronósticos integrando una mezcla más amplia de señales externas, como fluctuaciones meteorológicas, calendarios de eventos locales y sentimiento social en categorías específicas.³⁴ La capacidad de la IA para absorber estas variables en tiempo real permite ajustes dinámicos en los niveles de stock de seguridad y el reequilibrio diario del transporte.³⁴

Investigaciones en puertos automatizados muestran que nuevos algoritmos basados en programación lineal entera mixta (MIP) pueden reducir las tasas de reubicación de contenedores a niveles de entre el 12% y el 18%, manteniendo tiempos de respuesta de milisegundos que son esenciales para la programación en tiempo real de grúas y vehículos autónomos.³⁶ Estos sistemas integran modelos de gemelos digitales para simular escenarios de congestión y optimizar la secuencia de carga y descarga en función del puerto de destino y las prioridades temporales.³⁶

Visibilidad Predictiva y Gestión de Excepciones

Las plataformas de visibilidad logística ahora utilizan modelos predictivos de hora estimada de llegada (ETA) que filtran falsas alarmas y agrupan retrasos relacionados.³⁴ Al analizar datos históricos de rendimiento de transportistas y patrones de congestión en puertos, la IA puede predecir interrupciones semanas antes de que ocurran, permitiendo a los comerciantes ajustar sus rutas y proteger sus acuerdos de nivel de servicio (SLA).²⁴

Metodologías de Proyección Macroeconómica: El

Modelo GIMF del FMI

Para comprender el impacto global de la IA, el FMI utiliza el Modelo Monetario y Fiscal Integrado Global (GIMF), un modelo de equilibrio general dinámico (DSGE) multiregión y multisector que permite simular choques tecnológicos y cambios en la productividad.²⁵

Estructura del Modelo GIMF para la IA

El modelo GIMF divide la economía de cada región en tres sectores clave para capturar la heterogeneidad de la adopción de la IA:

1. **Sector No Transable:** Compuesto principalmente por servicios y construcción, donde la IA puede generar grandes saltos de productividad que impactan el bienestar doméstico.
2. **Sector Transable:** Incluye agricultura, manufactura, minería y transporte.
3. **Sector Intensivo en IA:** Un sector compuesto por bienes transables y servicios más expuestos a la IA (como farmacéutica, computación, finanzas y telecomunicaciones). Este sector se caracteriza por cadenas de valor globales donde las empresas utilizan la producción de este mismo sector como insumo intermedio.³⁸

El impacto de la IA entra en el modelo a través de un canal de Productividad Total de los Factores (TFP). La magnitud del choque se calibra en función de tres factores críticos por país: Exposición (composición sectorial y de tareas), Preparación (infraestructura digital y habilidades de la fuerza laboral) y Acceso (disponibilidad de datos y hardware esencial).³⁸

Resultados de la Simulación y Desigualdad Global

Las simulaciones indican que la IA exacerbará la desigualdad de ingresos entre países, beneficiando de manera desproporcionada a las economías avanzadas. El impacto estimado en el crecimiento de las economías avanzadas podría ser más del doble que en los países de bajos ingresos.³⁸ En un escenario de alta productividad, la IA podría impulsar el crecimiento del PIB de las economías de ingresos altos en un 14%, en comparación con solo un 8% para las economías de bajos ingresos que enfrentan barreras estructurales para la adopción tecnológica.¹

Además, la IA podría generar un "efecto Balassa-Samuelson inverso". Tradicionalmente, un aumento de la productividad en el sector transable tiende a apreciar el tipo de cambio real. Sin embargo, dado que la IA tiene un impacto masivo en la productividad del sector no transable (servicios), este mecanismo podría verse alterado, reduciendo el papel tradicional de los ajustes del tipo de cambio en el equilibrio comercial global.³⁸

El Impacto en el Mercado Laboral y la Estructura de Costos

La adopción de la IA está transformando la naturaleza del trabajo y la composición de la demanda laboral en el comercio internacional. La OMC señala que la sustitución de tareas laborales por IA será más pronunciada en las ocupaciones de habilidades medias y altas que en las de bajas habilidades.¹

Sustitución de Tareas y Primas Salariales

Contrario a la automatización robótica anterior que afectó principalmente a los trabajadores manuales de baja calificación, la IA generativa y analítica tiene como

objetivo tareas de procesamiento de información y toma de decisiones.⁴⁰ Se estima que entre el 7% y el 9% de las tareas de los trabajadores calificados podrían ser reemplazadas por IA, mientras que en sectores como la manufactura textil, clasificada como de baja intensidad en IA, el impacto es de solo el 3%.²

Este cambio podría llevar a un estrechamiento de la brecha salarial en las economías avanzadas, no por un aumento de los salarios bajos, sino por una reducción en la demanda de mano de obra de oficina y analítica de alto costo.¹ Simultáneamente, el costo de utilizar capital (la tasa de alquiler del capital) aumentará en relación con los salarios debido a que la IA es una tecnología intensiva en capital y datos.¹

La Fuerza Laboral en Países en Desarrollo

Muchos países en desarrollo ya están participando en la cadena de valor de la IA a través de actividades de recolección de datos, anotación y moderación de contenido.¹ Sin embargo, garantizar una compensación justa y protección laboral en este "trabajo de datos" sigue siendo un desafío sistémico. Además, la IA podría erosionar la ventaja comparativa de las economías que dependen de la mano de obra de bajo costo y baja calificación si la producción se vuelve excesivamente intensiva en capital.¹

Desafíos Técnicos: Silos de Datos y Fragmentación Regulatoria

El potencial de la IA en el comercio se ve limitado por barreras estructurales relacionadas con la gestión de la información. Los "silos de datos" —depósitos de información aislados inaccesibles para otros departamentos o sistemas— son el

principal obstáculo para obtener una visión holística de las operaciones comerciales.⁴¹

Causas y Consecuencias de los Silos

Los silos de datos surgen de decisiones de herramientas a nivel de equipo, sistemas heredados que no se integran y una gobernanza de datos inmadura.⁴² En el comercio transfronterizo, esto se traduce en una falta de visibilidad en la cadena de suministro, discrepancias en los indicadores clave de rendimiento (KPI) y una toma de decisiones lenta y reactiva. Además, las preocupaciones sobre la seguridad y el cumplimiento de leyes como el GDPR o las leyes de localización de datos en China incentivan a las organizaciones a mantener sus datos "amurallados".⁴⁴

Para romper estos silos, las organizaciones están adoptando arquitecturas de "Reverse ETL" y plataformas de datos automatizadas que crean una "fuente única de verdad" accesible para todos los usuarios autorizados en tiempo real.⁴¹ Sin embargo, la integración de datos de fuentes internacionales sigue siendo compleja debido a la falta de estándares universales y la persistencia de riesgos de soberanía digital.⁴³

Aprendizaje Federado como Solución de Privacidad

Una respuesta técnica prometedora a los riesgos de privacidad y confidencialidad es el Aprendizaje Federado (*Federated Learning*). Esta técnica permite entrenar modelos de IA en conjuntos de datos sensibles sin mover los datos de su ubicación original.⁴⁷ En lugar de centralizar los datos, el algoritmo se envía a cada "nodo" (por ejemplo, un banco o una aduana), donde se entrena localmente. Solo las actualizaciones del modelo (gradientes) se envían de vuelta a un servidor central para ser agregadas en un modelo global mejorado.⁴⁷

En un caso de uso práctico coordinado por Swift, diez instituciones financieras

utilizaron el aprendizaje federado para identificar transacciones anómalas y fraudes. El modelo, entrenado en datos locales de cada banco sin compartir información de clientes, fue el doble de efectivo en identificar fraudes que los modelos entrenados en un solo conjunto de datos institucional.⁵⁰ El aprendizaje federado cumple con los principios de "privacidad por diseño" del GDPR al garantizar la minimización de datos y la limitación de la finalidad.⁴⁷

El Marco Regulatorio Global: De la Innovación a la Restricción

El año 2025 marca un punto de inflexión en la regulación de la IA. La **Ley de IA de la Unión Europea** ha entrado en vigor de forma escalonada, estableciendo prohibiciones sobre prácticas inaceptables y requisitos estrictos para los sistemas de IA de alto riesgo.⁵¹

La Ley de IA de la UE y sus Implicaciones Comerciales

Desde febrero de 2025, están prohibidas en la UE las prácticas de IA que impliquen manipulación dañina o explotación de vulnerabilidades.⁵¹ Para agosto de 2025, entraron en vigor las reglas para modelos de IA de propósito general (GPAI), exigiendo transparencia y cumplimiento de las normas de derechos de autor. Las empresas que operan en el mercado europeo deben realizar evaluaciones de riesgo adecuadas, garantizar la alta calidad de los conjuntos de datos para minimizar sesgos discriminatorios y permitir la supervisión humana.⁵¹

Simultáneamente, surge una brecha regulatoria entre las diferentes regiones. Mientras que la UE se enfoca en la protección de derechos y la seguridad, otras

jurisdicciones avanzan con políticas más orientadas a la soberanía digital y la promoción de campeones nacionales.⁴⁴ Esta fragmentación regulatoria aumenta los costos de cumplimiento para los proveedores de servicios digitales transfronterizos y puede actuar como una barrera comercial no arancelaria, restringiendo el flujo de servicios esenciales para la innovación.⁴⁴

AI Convergence vs. AI Divergence

El Foro Económico Mundial (WEF) advierte sobre dos escenarios posibles para el futuro del comercio digital:

1. **AI Convergence (Convergencia de IA):** Un escenario donde la implementación exitosa y coordinada de la IA aumenta el crecimiento real del comercio en 13.6 puntos porcentuales, con beneficios distribuidos de manera uniforme entre todas las economías gracias a la interoperabilidad y la confianza mutua.³
2. **AI Divergence (Divergencia de IA):** Un escenario donde los beneficios se concentran en "islas comerciales" impulsadas por IA, exacerbando la desigualdad global y limitando la participación de las economías que no pueden cumplir con los altos estándares tecnológicos o regulatorios.³

Conclusiones y Perspectivas Estratégicas hacia 2040

La integración de la IA en la previsión de flujos comerciales es una fuerza transformadora que redefine la competitividad de las naciones y la eficiencia de las corporaciones. Las proyecciones hacia 2040 sugieren un panorama donde el comercio mundial será significativamente más digital, rápido y resiliente, pero también más intensivo en capital y datos.¹

Para navegar este nuevo paradigma, los tomadores de decisiones deben centrarse en cuatro pilares fundamentales de implementación:

- **Asegurar la interoperabilidad de los sistemas:** El éxito de iniciativas como el Proyecto Aperta demuestra que la armonización de protocolos técnicos y estándares de API es esencial para que los datos fluyan sin fricciones a través de las fronteras.³
- **Fomentar la confianza y la transparencia:** La adopción de marcos éticos y herramientas de IA explicable es crítica para que los sistemas de cumplimiento aduanero y calificación crediticia sean aceptados por las autoridades y el público.³
- **Invertir en infraestructura y capital humano:** Cerrar la brecha digital requiere no solo centros de datos y cables submarinos, sino también una fuerza laboral capaz de colaborar con la IA y gestionar infraestructuras complejas de gemelos digitales y logística autónoma.³
- **Fortalecer las alianzas público-privadas:** La alineación de incentivos entre gobiernos y empresas tecnológicas es necesaria para desarrollar ecosistemas de innovación locales que puedan adaptarse a las realidades específicas de cada mercado.³

El comercio internacional en 2025 se encuentra en una encrucijada. La IA ofrece el mapa para salir de la incertidumbre macroeconómica, proporcionando las herramientas para una previsión más precisa y una operación más ágil. Sin embargo, el riesgo de una nueva "brecha digital" es real. Solo mediante una cooperación internacional robusta en estándares, gobernanza de datos y transferencia tecnológica, la IA podrá cumplir su promesa de ser el motor de un crecimiento global inclusivo y sostenible durante las próximas dos décadas.

Capítulo IV

Análisis Técnico y Sistémico de Métodos Estadísticos e Inteligencia Artificial en Estructuras Económicas No Fiduciarias

La arquitectura de los sistemas económicos globales se encuentra en un punto de inflexión histórico, impulsado por la erosión de la confianza en los modelos fiduciarios tradicionales y la emergencia de tecnologías de computación avanzada que permiten una gestión de valor basada en leyes matemáticas y recursos físicos. Mientras que el dinero fiduciario carece de valor intrínseco y deriva su utilidad del decreto gubernamental y el acuerdo colectivo para el intercambio ¹, los sistemas no fiduciarios proponen un retorno a la escasez demostrable, ya sea a través de mercancías físicas como el oro o mediante algoritmos descentralizados que limitan la oferta de activos digitales.² En este escenario, la aplicación de métodos estadísticos complejos y modelos de inteligencia artificial (IA) no es simplemente una mejora operativa, sino un requisito estructural para garantizar la estabilidad, la eficiencia y la seguridad de sistemas que carecen de una autoridad centralizada para intervenir en momentos de crisis.³

Fundamentos de la Economía No Fiduciaria y la Gestión Técnica de Recursos

La distinción fundamental entre los sistemas fiduciarios y los no fiduciarios radica en su mecanismo de respaldo y suministro. El dinero fiduciario es emitido por

gobiernos y controlado por bancos centrales, lo que permite una política monetaria discrecional que puede derivar en procesos inflacionarios o deflacionarios según las necesidades del Estado.¹ Por el contrario, los sistemas no fiduciarios, como las criptomonedas o la economía basada en recursos (EBR), operan bajo reglas predefinidas. En el caso de las criptomonedas, la oferta suele estar limitada algorítmicamente —como el tope de 21 millones de Bitcoin—, mientras que la EBR se fundamenta en lo que es posible lograr con los recursos materiales, tecnológicos y humanos disponibles en lugar del capital financiero.¹

La transición hacia una gestión técnica de la economía requiere un sistema de monitoreo en tiempo real que reemplace la toma de decisiones políticas subjetivas por una administración basada en datos objetivos.⁵ En una EBR, el objetivo principal es la satisfacción de las necesidades humanas y la sostenibilidad ambiental, lo que exige una red de sensores y satélites que capturen constantemente información sobre la producción, el consumo y la disponibilidad de materias primas.⁵ Esta infraestructura de datos permite que sistemas de cómputo centralizados analicen la información en fracciones de segundo, eliminando la necesidad de procesos democráticos lentos o juicios humanos falibles en la asignación de recursos.⁵

Comparativa Estructural de Sistemas Económicos y sus Mecanismos de Control

El diseño de estos sistemas busca resolver el problema de la escasez artificial. En el modelo actual, si una cosecha es abundante, los precios bajan, lo que a menudo lleva a la destrucción de excedentes para proteger los márgenes de ganancia.⁵ Una economía basada en recursos, gestionada mediante IA, priorizaría la distribución eficiente de esa abundancia, utilizando algoritmos de logística para enviar los recursos

allí donde la demanda real lo requiera, eliminando el desperdicio inherente al sistema de precios.⁵

Modelado Estadístico y Aprendizaje Automático para la Predicción de Volatilidad

Los activos no fiduciarios, especialmente en el ámbito digital, presentan una volatilidad significativamente mayor que las monedas fiduciarias debido a la ausencia de mecanismos de estabilización institucional y a la especulación intensa.¹ Los métodos estadísticos tradicionales, como los modelos ARIMA (Autoregressive Integrated Moving Average), han sido utilizados históricamente para el análisis de series temporales, asumiendo que el valor futuro de una variable es una función lineal de sus valores pasados y errores anteriores.⁹ Sin embargo, la naturaleza altamente no lineal y los cambios de régimen frecuentes en los mercados criptográficos limitan la eficacia de estos modelos lineales.⁸

Para abordar estas complejidades, se han integrado modelos de la familia GARCH (Generalized Autoregressive Conditional Heteroskedasticity), los cuales permiten modelar la varianza condicional como un proceso que cambia en el tiempo.⁸ El modelo estándar GARCH(1,1) se expresa mediante la ecuación:

$$\sigma_t^2 = \omega + \alpha \epsilon_{t-1}^2 + \beta \sigma_{t-1}^2$$

Donde σ_t^2 es la varianza en el tiempo t , ω es una constante, ϵ_{t-1}^2 representa los choques del periodo anterior y σ_{t-1}^2 es la varianza del periodo anterior.⁸ A pesar de su capacidad para capturar el agrupamiento de volatilidad (volatility clustering), estos modelos estadísticos a menudo ignoran la asimetría de los choques, donde las noticias negativas suelen

generar una mayor volatilidad que las positivas.⁸ Esto ha llevado al desarrollo de modelos como el EGARCH (Exponential GARCH), que utiliza logaritmos para asegurar que la varianza siempre sea positiva y permite capturar efectos asimétricos de manera más precisa.⁸

Evolución hacia Modelos de Aprendizaje Automático y Redes Neuronales

La inteligencia artificial ha transformado el pronóstico de volatilidad mediante el uso de redes neuronales recurrentes (RNN) y, más específicamente, de modelos de Memoria a Corto y Largo Plazo (LSTM).¹² Las LSTM están diseñadas para superar el problema del desvanecimiento del gradiente en las RNN tradicionales, permitiendo que el modelo retenga información de dependencias temporales largas, algo crucial en mercados donde los eventos históricos pueden influir en el comportamiento actual de manera no obvia.⁸

Estudios comparativos indican que los modelos de aprendizaje automático basados en conjuntos (Ensemble Learning), como Random Forest y XGBoost, ofrecen una robustez superior frente al ruido del mercado en comparación con los modelos econométricos clásicos.¹¹ Estos modelos funcionan mediante la construcción de múltiples árboles de decisión y la combinación de sus resultados para reducir la varianza y el sesgo.¹¹ La integración de indicadores técnicos, datos de volumen y sentimiento de redes sociales en estos modelos permite capturar la dinámica del mercado con una precisión reportada de hasta el 72% en la clasificación de la dirección del precio.¹¹

La efectividad de estos modelos depende críticamente de la calidad de los

datos y de la ingeniería de características (feature engineering). En el contexto de activos no fiduciarios, es esencial incluir datos de libros de órdenes, métricas on-chain (como el movimiento de carteras "ballena") y análisis de sentimiento extraído de plataformas como X (Twitter) o Reddit mediante procesamiento de lenguaje natural (NLP).⁶

IA y Aprendizaje por Refuerzo en la Optimización de Tokenomics

En los sistemas económicos descentralizados, la tokenomics —el conjunto de reglas que rigen la economía del token— actúa como la política monetaria programada del ecosistema.⁶ Los modelos tradicionales de tokenomics suelen ser rígidos, con programas de emisión fijos que no pueden adaptarse a choques externos o cambios bruscos en la demanda, lo que a menudo resulta en colapsos de liquidez o hiperinflación.⁶ La inteligencia artificial, y específicamente el Aprendizaje por Refuerzo (Reinforcement Learning - RL), permite la creación de modelos de emisión y quema dinámicos que se autoajustan en tiempo real para mantener el equilibrio económico.¹⁶

Un agente de RL aprende a interactuar con un entorno económico mediante un proceso de prueba y error, donde cada acción (como aumentar la recompensa de staking o acelerar la quema de tokens) genera una recompensa o penalización basada en un objetivo predefinido, como la estabilidad del precio o la retención de usuarios.⁶ Este proceso se formaliza habitualmente como un Proceso de Decisión de Markov (MDP), definido por la estructura (S, A, T, R, γ) ¹⁷:

- **Espacio de Estados (S):** Incluye variables como liquidez total bloqueada (TVL),

volumen de intercambio y volatilidad actual.⁶

- **Espacio de Acciones (A):** Parámetros ajustables por el protocolo, como la tasa de emisión de nuevos tokens o el porcentaje de comisiones que se queman.⁶
- **Función de Transición (T):** La probabilidad de que el ecosistema pase a un estado más estable dadas las acciones del agente.¹⁷
- **Función de Recompensa (R):** Diseñada para incentivar comportamientos que alineen los intereses de los desarrolladores, inversores y usuarios.¹⁷

Mecanismos de Estabilización Algorítmica y DAOs

Las Organizaciones Autónomas Descentralizadas (DAOs) utilizan estos modelos para automatizar la gobernanza. La IA puede analizar datos históricos de votaciones y propuestas para prever las consecuencias de ciertas decisiones económicas que los humanos podrían pasar por alto.⁶ Además, en ecosistemas de finanzas descentralizadas (DeFi), los modelos de IA protegen la paridad de las stablecoins algorítmicas mediante la contracción de la oferta cuando hay presión de venta o su expansión cuando la demanda aumenta excesivamente, actuando como un banco central autónomo y transparente.⁶

La personalización de incentivos es otra aplicación clave del RL. En lugar de sistemas de recompensas uniformes que a menudo atraen capital "mercenario" de corto plazo, la IA puede identificar a los usuarios que aportan valor genuino al ecosistema —como aquellos con compromisos de staking a largo plazo o participación activa en la gobernanza— y asignarles incentivos específicos.¹⁶ Esto fortalece la lealtad del usuario y previene la inflación innecesaria provocada por recompensas indiscriminadas.¹⁶

Integridad y Seguridad en Redes Descentralizadas:

Detección de Anomalías

La naturaleza abierta y seudónima de los sistemas económicos no fiduciarios los hace susceptibles a actividades ilícitas como el lavado de dinero y el fraude transaccional.¹⁹ La detección de anomalías mediante IA ha evolucionado desde simples reglas estáticas hacia modelos predictivos que analizan patrones de comportamiento complejos en conjuntos de datos masivos.²¹ Estos sistemas identifican irregularidades que podrían indicar fraude o ataques antes de que causen daños significativos, permitiendo una respuesta proactiva en lugar de reactiva.²⁰

Metodologías de Detección y Evaluación de Modelos

Los sistemas de detección de anomalías emplean tres enfoques principales:

1. **Detección Estadística:** Utiliza técnicas como puntuaciones Z y distribuciones de probabilidad para encontrar desviaciones del comportamiento "normal" establecido históricamente.²¹
2. **Aprendizaje Supervisado:** Utiliza datos etiquetados de fraudes conocidos para entrenar clasificadores como XGBoost, que ha demostrado una precisión superior al 95% en la detección de fraudes con tarjetas de crédito y criptomonedas.¹⁹
3. **Aprendizaje No Supervisado:** Crucial cuando no hay datos etiquetados disponibles. Algoritmos como Isolation Forest aislan puntos de datos atípicos dividiendo el espacio de características de manera aleatoria; las anomalías suelen requerir menos divisiones para ser aisladas.²¹

Un desafío crítico en la detección de fraude es el desbalanceo de los datos, donde las transacciones fraudulentas suelen representar menos del 1% del total.¹⁹ La precisión simple puede ser engañosa en estos casos (un modelo que predice siempre "no fraude" tendría un 99% de precisión), por lo que se priorizan métricas como el F1-score y el Recall para asegurar que la mayoría de los fraudes sean capturados, incluso a costa de una mayor carga de revisión manual por falsos positivos.¹⁹

El Papel de la Simulación y los Datos Sintéticos en la Resiliencia Económica

La falta de datos históricos para eventos de crisis extrema —los denominados "Cisnes Negros"— dificulta el entrenamiento de modelos de IA robustos en sistemas no fiduciarios que son relativamente jóvenes.¹² La generación de datos sintéticos surge como una solución técnica que crea conjuntos de datos artificiales que mantienen las propiedades estadísticas de los datos reales sin comprometer la privacidad ni depender de la historia limitada.²⁴

Mediante el uso de Redes Generativas Antagónicas (GANs), los investigadores pueden simular miles de escenarios económicos posibles para probar la resistencia de un protocolo antes de su lanzamiento.²⁴ En una GAN, un generador crea datos sintéticos mientras un discriminador intenta diferenciar entre los datos reales y los artificiales. Este proceso competitivo refina el generador hasta que los datos sintéticos son estadísticamente indistinguibles de los reales, permitiendo a los economistas diseñar estrategias de mitigación de riesgos para situaciones que nunca han ocurrido pero que son teóricamente probables.²⁴

Privacidad y Cumplimiento mediante Aprendizaje Federado

La gestión de datos en sistemas descentralizados debe equilibrar la utilidad analítica con la privacidad del usuario y las regulaciones internacionales como el GDPR.²⁸ El Aprendizaje Federado (Federated Learning) permite que múltiples instituciones colaboren en el entrenamiento de un modelo global de detección de fraude o gestión de recursos sin intercambiar sus bases de datos locales.¹⁹ Solo los parámetros del modelo (gradientes) se comparten y se agregan mediante protocolos seguros en la cadena de bloques, garantizando que la información sensible permanezca bajo el control del propietario original.¹⁹

Optimización de la Asignación de Recursos Físicos y Digitales

Más allá de los mercados financieros, la IA aplicada a economías no fiduciarias como la EBR busca la optimización absoluta de los recursos físicos. En un sistema donde no existe el dinero, la eficiencia se mide por el ahorro energético y la reducción del desperdicio.⁵ Los modelos de optimización basados en algoritmos lineales y no lineales se utilizan para planificar presupuestos de recursos y producción industrial.²⁶

Por ejemplo, los sistemas de gestión energética en ciudades inteligentes utilizan IA para predecir la demanda de electricidad basándose en patrones meteorológicos y de ocupación, optimizando el uso de fuentes renovables y reduciendo el consumo total entre un 20% y un 40%.³⁰ En el ámbito digital, el aprendizaje por refuerzo se aplica para optimizar la infraestructura de computación en la nube, logrando mejoras del 38.7% en el rendimiento y reducciones del 42.3% en el consumo de energía en el entrenamiento de modelos de IA a gran escala.³¹

Esta eficiencia se extiende a la "producción perimetral", un concepto de la EBR

donde la IA diseña ciudades de manera circular para que los alimentos y la energía se produzcan en la periferia inmediata de los centros de población, minimizando la necesidad de transporte de larga distancia y los riesgos asociados a las interrupciones en las cadenas de suministro globales.⁵

Desafíos Metodológicos y Complejidad Socio-Técnica

A pesar de los beneficios evidentes, la aplicación de IA a sistemas económicos no fiduciarios enfrenta obstáculos significativos derivados de la propia complejidad de los sistemas adaptativos. Los modelos de IA no operan en el vacío; están inmersos en entornos donde las instituciones, los mercados y los usuarios responden estratégicamente a las regulaciones y a las capacidades tecnológicas.³³ Esto significa que las intervenciones regulatorias pueden tener efectos no lineales, donde pequeños cambios producen resultados desproporcionados o grandes intervenciones son neutralizadas por la adaptación del sistema.³³

La dependencia de datos históricos también presenta riesgos. Los modelos de IA entrenados en datos pasados pueden fallar catastróficamente ante situaciones sin precedentes, ya que carecen de la capacidad de razonamiento causal y comprensión del mundo físico que poseen los humanos.³⁴ Además, la concentración de poder en los proveedores de infraestructura de IA (especialmente en términos de hardware especializado como las GPUs) introduce nuevos riesgos de estabilidad financiera, ya que las fallas correlacionadas en estos proveedores podrían paralizar gran parte de la economía digital descentralizada.³⁶

La Paradoja de la Estabilidad Algorítmica

Un hallazgo crítico en la teoría de juegos aplicada a la estabilidad financiera es que la IA puede disminuir la volatilidad diaria pero aumentar el riesgo de cola (tail risk).⁴ Al procesar la información de manera más eficiente y actuar a velocidades de máquina, los algoritmos de IA tienden a suavizar las fluctuaciones menores del mercado. Sin embargo, en momentos de estrés genuino, el uso de modelos similares y fuentes de datos comunes puede llevar a un comportamiento sincronizado que amplifica los choques, haciendo que las crisis sean más rápidas e intensas que las experimentadas históricamente.⁴

Este fenómeno se ve exacerbado por la "opacidad del sistema" y el apalancamiento excesivo en sectores no bancarios (NBFI), que ahora juegan un papel creciente en los mercados de criptoactivos y crédito privado.³⁸ Las autoridades financieras enfrentan el reto de supervisar un entorno donde la velocidad de innovación supera la capacidad de recolección de datos y actualización de marcos legales.³⁷

Hacia una Nueva Gobernanza Económica Basada en Datos

La convergencia de la inteligencia artificial y los sistemas económicos no fiduciarios ofrece una oportunidad sin precedentes para rediseñar la interacción humana con el valor y los recursos. Mientras que los sistemas fiduciarios dependen de la gestión política de la escasez, los sistemas emergentes permiten una gestión técnica de la abundancia y la estabilidad algorítmica. La implementación exitosa de estos métodos requiere no solo avances en la precisión de los modelos estadísticos, sino también una profunda comprensión de la ética de los datos, la privacidad y la resiliencia sistémica frente a comportamientos emergentes.

La transición hacia una economía basada en recursos o un sistema financiero puramente algorítmico no está exenta de riesgos, pero la capacidad de la IA para procesar la complejidad, detectar fraudes de manera autónoma y optimizar la distribución de bienes sugiere que el futuro de la economía será menos una cuestión de opinión política y más un campo de ingeniería de alta precisión. La clave de la estabilidad en esta nueva era no reside en resistir el cambio tecnológico, sino en asegurar que los marcos de gobernanza evolucionen a la par de las capacidades de los agentes económicos artificiales.

La integración de métodos estadísticos con inteligencia artificial en sistemas no fiduciarios representa el paso definitivo hacia una economía post-fiduciaria donde el valor se gestiona mediante la transparencia del código y la realidad física de los recursos. La superioridad de los modelos de aprendizaje automático frente a los métodos estadísticos tradicionales en la predicción de volatilidad y la detección de fraudes es un indicador de la madurez tecnológica alcanzada. Sin embargo, la resiliencia del sistema a largo plazo dependerá de la capacidad de los diseñadores de protocolos para integrar mecanismos de seguridad federados, generar simulaciones robustas de escenarios extremos y evitar la homogeneización de algoritmos que podría inducir fallas sistémicas. En última instancia, la inteligencia artificial actúa como el sistema nervioso central de una nueva estructura económica que prioriza la eficiencia, la sostenibilidad y la autonomía individual sobre el control centralizado.

Capítulo V

Métodos estadísticos con inteligencia artificial aplicados a plataformas Fintech

La industria de los servicios financieros ha convergido hacia un estado de digitalización absoluta, donde la distinción entre las instituciones bancarias tradicionales y las empresas de tecnología financiera, o Fintech, se ha vuelto casi imperceptible debido a la adopción masiva de métodos estadísticos avanzados y arquitecturas de inteligencia artificial.¹ En el umbral de 2025, el sector Fintech no solo representa una alternativa ágil a la banca convencional, sino que se ha consolidado como el motor principal de la innovación económica global, democratizando el acceso a servicios que antes eran exclusivos de segmentos institucionales o de alto patrimonio.³ Esta transformación estructural se apoya en una sofisticación sin precedentes de los algoritmos de aprendizaje automático, el procesamiento de grandes volúmenes de datos en tiempo real y una integración profunda de modelos probabilísticos que permiten una gestión del riesgo y una personalización del servicio con niveles de precisión quirúrgica.⁵

Evolución y maduración del ecosistema Fintech global

El crecimiento del sector Fintech ha sido exponencial, especialmente en regiones con alta demanda de inclusión financiera como América Latina y el Caribe, donde el número de plataformas tecnológicas ha crecido un 340% desde 2017,

superando las 3,000 empresas activas al cierre de 2023.⁴ Este fenómeno no es aislado; responde a una tendencia global de migración hacia modelos de negocio digitales que priorizan la agilidad, la reducción de costos operativos y la capacidad de atender a segmentos de la población históricamente desatendidos, como las micro, pequeñas y medianas empresas (mipymes), mujeres y jóvenes.³ En las economías emergentes, las Fintech han logrado penetrar en áreas rurales utilizando estrategias multicanal que combinan redes de agentes con servicios multilingües y educación financiera, superando las barreras de acceso a internet que todavía afectan a gran parte de la población mundial.³

La infraestructura técnica que sustenta este crecimiento ha evolucionado hacia la estandarización global de los datos. La adopción del estándar ISO 20022 para la mensajería financiera es un pilar fundamental en 2025, permitiendo una interoperabilidad fluida entre sistemas de pagos de alto valor (HVPS+), pagos transfronterizos (CBPR+) y sistemas de pagos instantáneos (IP+).⁷ Esta estandarización no solo mejora la eficiencia del procesamiento directo y reduce los costos de conciliación, sino que proporciona un diccionario de datos común que alimenta los modelos de inteligencia artificial con información estructurada y de alta calidad, facilitando la detección de fraudes y el cumplimiento regulatorio a nivel internacional.⁷

La inversión en tecnología financiera, aunque experimentó una corrección en términos de capital de riesgo entre 2021 y 2022, ha mostrado una resiliencia notable, representando el 43% del total de la inversión en el rubro tecnológico en regiones clave.⁴ Este flujo de capital se ha redirigido desde el crecimiento a cualquier costo hacia la rentabilidad y la solidez operativa, donde la inteligencia artificial juega un papel crítico. El 80% de las Fintech encuestadas en 2025 afirma haber implementado

IA en múltiples áreas de su negocio, principalmente en la automatización de procesos y el servicio al cliente, logrando mejoras significativas en la experiencia del usuario y en la reducción de gastos operativos.³

Metodologías estadísticas y aprendizaje automático en la gestión del riesgo crediticio

El modelado del riesgo de crédito constituye el corazón operativo de cualquier plataforma de préstamos o financiamiento. La transición desde los métodos estadísticos tradicionales, basados en regresiones logísticas simples, hacia arquitecturas de aprendizaje profundo y modelos de ensamble ha redefinido la precisión de las predicciones de incumplimiento.⁸ Mientras que la regresión logística (LR) y el análisis discriminante lineal (LDA) han sido los pilares históricos debido a su interpretabilidad y alineación con las normativas de Basilea, su capacidad para capturar interacciones no lineales complejas es limitada en comparación con las técnicas modernas.¹⁰

Comparativa de desempeño entre modelos tradicionales y avanzados

Estudios recientes realizados entre 2024 y 2025 demuestran que algoritmos como Random Forest (RF), XGBoost y las Redes Neuronales Profundas (DNN) superan consistentemente a los modelos econométricos clásicos en métricas de precisión, sensibilidad y el área bajo la curva (AUC).⁸ Por ejemplo, en el análisis de la probabilidad de incumplimiento (*Probability of Default*), las redes neuronales han mostrado un *Accuracy Ratio* de hasta el 71%, superando en cinco puntos porcentuales a la regresión logística tradicional, que promedia un 66%.¹³ Esta mejora, aunque

parezca marginal en términos porcentuales, se traduce en ahorros de millones de dólares en capital de reserva y pérdidas por impagos para las instituciones financieras de gran escala.¹⁰

La potencia de los modelos de *Machine Learning* reside en su capacidad para integrar fuentes de datos no convencionales. Las plataformas Fintech evalúan ahora la solvencia crediticia analizando el historial de transacciones detallado, los patrones de gasto en comercio electrónico, el comportamiento en redes sociales e incluso la cadencia de uso de aplicaciones móviles.⁶ Este enfoque permite la inclusión de clientes con "archivos delgados" (*thin-files*) o sin historial crediticio previo, expandiendo el mercado direccional de las Fintech mientras se mantiene un control estricto sobre el riesgo.⁶

Optimización y validación estadística de los modelos

Para garantizar la estabilidad y el rendimiento óptimo de estos sistemas, se emplean técnicas sofisticadas de ajuste de hiperparámetros. La optimización bayesiana, utilizando marcos de trabajo como Optuna, permite encontrar las configuraciones ideales para los modelos de ensamble (Stacking Ensembles) de manera eficiente, superando las búsquedas de cuadrícula (*grid search*) tradicionales.¹¹ Además, la validación de estos modelos ya no se limita a pruebas simples de precisión; se aplican pruebas estadísticas rigurosas como el test de McNemar y pruebas t-pareadas para confirmar la significancia estadística de las mejoras de rendimiento antes de su despliegue en entornos de producción.¹¹

La evaluación del rendimiento se basa en fórmulas matemáticas estandarizadas que permiten la comparación objetiva entre diferentes arquitecturas:

1. Tasa de Precisión (Accuracy Rate):

$$\text{Accuracy} = \frac{T_0 + T_1}{(T_0 + T_1) + (F_0 + F_1)}$$

Donde T_0 y T_1 son verdaderos positivos y negativos, mientras que F_0 y F_1 representan falsos negativos y positivos respectivamente.¹²

o F1 Score:

$$F1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$$

Siendo esta métrica vital en conjuntos de datos desbalanceados, comunes en el riesgo crediticio donde los casos de incumplimiento son una minoría.¹²

2. **Matriz de Confusión:** Una herramienta esencial para desglosar el tipo de errores que comete el modelo, permitiendo a los gestores de riesgo decidir si prefieren minimizar los falsos positivos (denegar crédito a buenos clientes) o los falsos negativos (aprobar crédito a clientes que incumplirán).¹²

Detección de fraude y análisis de anomalías en tiempo real

La ciberseguridad y la prevención del fraude han pasado de ser funciones de soporte a convertirse en pilares de la confianza del cliente en el ecosistema Fintech. Los sistemas basados en reglas estáticas y revisiones manuales, que antes eran el estándar, han demostrado ser insuficientes frente a la sofisticación de los ataques modernos, generando tasas de falsos positivos que pueden oscilar entre el 12% y el

20%.¹⁵ En 2025, la detección de fraude mediante inteligencia artificial permite procesar flujos masivos de datos en milisegundos, identificando patrones de comportamiento sospechosos antes de que la transacción se complete.¹⁵

Arquitecturas para el análisis de series temporales

El fraude financiero es intrínsecamente un problema de series temporales. Las transacciones de un usuario forman una secuencia con dependencias temporales y contextuales que deben ser analizadas para detectar desviaciones.¹⁵ Las redes neuronales recurrentes (RNN) y, específicamente, las arquitecturas de memoria de corto y largo plazo (LSTM), son fundamentales en este ámbito. Las LSTM superan el problema del desvanecimiento del gradiente de las RNN tradicionales, permitiendo al sistema "recordar" patrones de gasto a largo plazo y detectar si una serie de transacciones recientes, aunque parezcan normales individualmente, conforman una secuencia anómala indicativa de un ataque de toma de control de cuenta (ATO).¹⁵

Además de las LSTM, las Redes Convolucionales Temporales (TCN) han ganado tracción en 2025. A diferencia de las arquitecturas recurrentes, las TCN procesan la información de manera paralela a través de capas convolucionales, lo que las hace más rápidas de entrenar y, a menudo, más precisas en la detección de anomalías en datos de alta frecuencia.¹⁹ Estudios comparativos indican que las TCN pueden alcanzar una estabilidad de modelo superior y una menor latencia de inferencia, factores críticos para los sistemas de bloqueo de transacciones en tiempo real.¹⁸

Biometría conductual y redes de grafos (GNN)

Una de las innovaciones más profundas es el uso de la biometría conductual asistida por IA. Los sistemas monitorean continuamente micro-patrones como la

cadencia de las pulsaciones de teclas, la presión ejercida sobre la pantalla táctil del móvil y las trayectorias del ratón.¹⁵ Estas señales forman una "firma de comportamiento" única que es extremadamente difícil de replicar para un atacante o un bot. Cuando el sistema detecta una desviación de esta línea base, puede forzar una verificación adicional o bloquear la cuenta de forma preventiva.¹⁵

Por otro lado, el análisis relacional mediante Redes Neuronales de Grafos (GNN) permite identificar estructuras de fraude complejas que el análisis tabular ignoraría. Las GNN analizan las conexiones entre cuentas, dispositivos, direcciones IP y ubicaciones geográficas, facilitando la detección de redes de lavado de dinero, cuentas "mula" y ataques coordinados de ingeniería social.¹⁵

La eficiencia de estos sistemas se mide por su capacidad de adaptación. El concepto de "deriva de concepto" (*concept drift*) es central en 2025: dado que los patrones de fraude evolucionan constantemente, los modelos de IA deben ser capaces de actualizarse de forma dinámica mediante aprendizaje en línea o reentrenamientos frecuentes basados en nuevos datos etiquetados.⁵ Plataformas modernas como Nected y Rapid Innovation ya implementan estos ciclos de retroalimentación, logrando reducciones drásticas en las pérdidas financieras por transacciones no autorizadas.¹⁶

Inteligencia artificial en el asesoramiento robótico y la gestión patrimonial

Los asesores robóticos (Robo-advisors) han pasado de ser simples calculadoras de asignación de activos a sistemas de gestión de patrimonio hiper-personalizados que integran principios de finanzas conductuales con optimización estadística avanzada.²² En 2025, el mercado global de robo-advisors se estima en más de 2 billones

de dólares en activos bajo gestión, impulsado por una base de usuarios que valora las bajas comisiones, la accesibilidad 24/7 y la toma de decisiones basada en datos objetivos.²⁴

Optimización de carteras más allá de la media-varianza

El modelo clásico de Markowitz, aunque sigue siendo una referencia, presenta limitaciones significativas, como la asunción de una distribución normal de los retornos y la sensibilidad extrema a los errores de estimación.²⁵ Para superar esto, los robo-advisors modernos utilizan el concepto de Dominancia Estocástica (SD) y, más específicamente, la Dominancia Estocástica de Segundo Grado Casi Absoluta (ASSD).²⁶ Este marco permite identificar carteras que superan a un índice de referencia para cualquier inversor con aversión al riesgo, considerando la distribución completa de las probabilidades en lugar de solo los dos primeros momentos (media y varianza).²⁶

Además, el modelado de dependencias complejas entre activos se realiza mediante Cúpulas Multivariantes. Las cúpulas permiten separar la estructura de dependencia de las distribuciones marginales de cada activo, lo que es crucial para capturar la "dependencia de cola" o el comportamiento conjunto de los mercados durante crisis financieras, donde las correlaciones tradicionales suelen romperse.²⁷ El uso de *vine copulas* jerárquicas facilita la construcción de modelos de riesgo para carteras globales diversificadas, mejorando la robustez del sistema ante eventos extremos.²⁷

Aprendizaje por refuerzo y mitigación de sesgos

El aprendizaje por refuerzo (RL) ofrece una ventaja estratégica en la gestión

dinámica de carteras. A diferencia de las estrategias basadas en reglas fijas, los algoritmos de RL, como el *Deep Reinforcement Learning* (DRL), aprenden a través de la interacción directa con el entorno de mercado, optimizando las señales de compra y venta para maximizar los retornos a largo plazo ajustados al riesgo.²³ Estos sistemas pueden simular millones de escenarios de mercado para encontrar la política de inversión óptima que se adapte a las condiciones cambiantes de volatilidad.²³

Un aspecto crítico de los robo-advisors en 2025 es su capacidad para identificar y mitigar los sesgos cognitivos de los inversores humanos. Mediante el uso de modelos predictivos de comportamiento, las plataformas pueden detectar signos de exceso de confianza o aversión extrema a la pérdida en los patrones de trading de los usuarios. Cuando se identifica un sesgo, el sistema puede intervenir mediante notificaciones educativas, ajustes automáticos de la tolerancia al riesgo o la implementación de una arquitectura de elección que fomente decisiones financieras más lógicas y racionales.³¹

Procesamiento de lenguaje natural y análisis de sentimiento financiero

La capacidad de interpretar el lenguaje humano ha abierto una nueva dimensión en el análisis de mercado. En un entorno donde la información fluye instantáneamente a través de noticias, redes sociales y comunicados corporativos, el Procesamiento de Lenguaje Natural (NLP) permite a las Fintech transformar datos no estructurados en señales operativas.³³

Evolución hacia la fusión bayesiana de modelos de lenguaje

El análisis de sentimiento financiero en 2025 ya no depende de diccionarios de palabras clave simples. El uso de modelos basados en transformadores, como BERT, FinBERT (especializado en términos financieros) y los modelos de la familia GPT (4o y 4o-mini), permite capturar matices semánticos, sarcasmo y jerga técnica con una precisión asombrosa.³⁶ Una de las metodologías más avanzadas introducidas recientemente es el **Bayesian Network LLM Fusion (BNLF)**.³⁷

El marco BNLF integra las predicciones de múltiples modelos de lenguaje (como FinBERT, RoBERTa y BERTweet) actuando como nodos en una red bayesiana. Esta arquitectura de " fusión tardía" modela las dependencias probabilísticas entre las predicciones de cada modelo, permitiendo que el sistema ajuste dinámicamente el peso de cada entrada según el contexto del texto.³⁷ Por ejemplo, en textos ruidosos procedentes de redes sociales, el peso del modelo BERTweet (entrenado en dicho dominio) aumenta automáticamente, mejorando la precisión general del sentimiento en aproximadamente un 6% sobre los modelos individuales.³⁷

Aplicaciones estratégicas del NLP

Las aplicaciones del NLP en el ecosistema Fintech son vastas:

1. **Análisis de llamadas de ganancias:** El sistema procesa transcripciones de llamadas trimestrales en segundos, detectando el tono de la gerencia y comparándolo con resultados históricos para predecir movimientos en el precio de las acciones.³³
2. **Monitoreo de cumplimiento:** Los algoritmos de NLP revisan miles de documentos legales y regulatorios para asegurar que la plataforma cumple con las normativas vigentes, reduciendo el riesgo de sanciones.³⁴
3. **Servicio al cliente hiper-personalizado:** Los chatbots impulsados por modelos

de lenguaje de gran escala (LLMs) proporcionan respuestas contextuales que no solo resuelven problemas técnicos, sino que también identifican el estado emocional del cliente, derivando casos sensibles a humanos cuando se detecta frustración.³⁴

La integración de estos sentimientos en modelos de series temporales estructurales bayesianas permite a los analistas cuantificar el impacto exacto de una noticia o un rumor en la volatilidad de un activo, facilitando estrategias de trading basadas en eventos que antes eran imposibles de automatizar con tal nivel de detalle.³⁵

Trading de alta frecuencia (HFT) y sistemas multi-agente

El trading de alta frecuencia representa la cúspide de la aplicación de la inteligencia artificial en la ejecución financiera. En 2025, el mercado ha evolucionado desde algoritmos de ejecución simples hacia sistemas de Aprendizaje por Refuerzo Multi-Agente (MARL), donde múltiples entidades autónomas interactúan y compiten en milisegundos.²⁹

La revolución de JaxMARL-HFT y la aceleración por GPU

La investigación y el despliegue de estos sistemas se han visto transformados por herramientas como JaxMARL-HFT. Este entorno, basado en JAX, aprovecha la aceleración por GPU para reducir el tiempo de entrenamiento de los modelos hasta 240 veces en comparación con las implementaciones tradicionales.⁴² Esta velocidad permite a las Fintech realizar barridos de hiperparámetros masivos y entrenar agentes utilizando años de datos de libros de órdenes (*Limit Order Book - LOB*) con cientos de

millones de registros.²⁹

Los resultados de estas estrategias son significativos. Agentes entrenados mediante algoritmos como *Proximal Policy Optimization* (PPO) y *Value Decomposition Networks* (VDN) han demostrado superar consistentemente a los puntos de referencia tradicionales en tareas de creación de mercado y ejecución de órdenes grandes, minimizando el impacto en el precio y maximizando los rendimientos ajustados al riesgo con Sharpe ratios reportados de hasta 3.42.²⁸

A pesar de los beneficios en términos de liquidez y descubrimiento de precios, la proliferación de sistemas HFT basados en IA plantea desafíos para la estabilidad del mercado. La supervisión regulatoria en 2025 se centra en prevenir el "comportamiento colusivo algorítmico" y garantizar que la velocidad de ejecución no erosione la equidad para los participantes humanos.⁴¹ Los modelos de optimización estocástica, como la integración de Euler-Maruyama y métodos basados en Heun, se utilizan para modelar la dinámica de precios en alta dimensión y evaluar el riesgo sistémico derivado de estas interacciones rápidas.⁴³

Inteligencia artificial explicable (XAI) y el nuevo marco regulatorio

A medida que los modelos estadísticos se vuelven más complejos, la necesidad de transparencia se ha vuelto imperativa. La "IA explicable" (XAI) no es solo una rama de la investigación en 2025, sino un requisito legal fundamental bajo normativas como la Ley de IA de la Unión Europea y la Ley Dodd-Frank en Estados Unidos.⁴⁴ Las instituciones financieras deben ser capaces de justificar por qué una IA denegó un crédito o marcó una transacción como fraudulenta, no solo para cumplir con la ley,

sino para mantener la confianza del consumidor.⁴⁴

Técnicas y principios de la XAI en finanzas

La explicabilidad en el entorno Fintech se rige por varios principios clave: transparencia, interpretabilidad, equidad y rendición de cuentas.⁴⁴ Para lograrlo, se emplean diversas técnicas estadísticas:

1. **SHAP (SHapley Additive Explanations):** Basado en la teoría de juegos, asigna a cada variable de entrada un valor de importancia para una predicción específica. Es el estándar de oro para explicar modelos de caja negra como XGBoost o redes neuronales en el scoring crediticio.¹⁰
2. **LIME (Local Interpretable Model-agnostic Explanations):** Crea modelos locales simplificados (como regresiones lineales) alrededor de una predicción específica para explicar el comportamiento del modelo complejo en ese punto.¹⁰
3. **Mapas de calor y visualización de atención:** Utilizados principalmente en modelos de visión o NLP para mostrar qué partes de un documento o una imagen influyeron más en la decisión del algoritmo.⁴⁴

La integración de la XAI en el ciclo de vida del desarrollo de software Fintech permite una gobernanza más sólida. Los equipos de cumplimiento pueden auditar los modelos en busca de sesgos discriminatorios (por ejemplo, por género o etnia) antes de que afecten a los clientes reales.⁴⁴ Además, la XAI facilita la supervisión humana (*Human-in-the-loop*), permitiendo que los expertos validen los resultados algorítmicos mediante explicaciones en lenguaje natural, lo que reduce drásticamente el tiempo de auditoría y aumenta la confianza de los reguladores.⁴⁵

Casos de estudio y líderes del mercado: Nubank,

Revolut y la infraestructura de pagos

El éxito de la aplicación de estos métodos se refleja en las métricas operativas de los líderes del sector. Empresas como Nubank y Revolut han demostrado que la ventaja tecnológica se traduce directamente en rentabilidad y cuota de mercado.

Nubank: Dominancia en América Latina mediante analítica profunda

Nubank se ha consolidado como uno de los bancos digitales más rentables del planeta, con más de 114 millones de usuarios en 2025.⁴⁷ Su modelo se basa en una plataforma de bajo costo y alta escala, donde la adquisición de clientes se apoya en un 80% en recomendaciones orgánicas impulsadas por una experiencia de usuario superior.⁴⁷ Mediante el uso de analítica avanzada y finanzas abiertas (*Open Finance*), Nubank ha logrado penetrar en segmentos de préstamos de nómina y crédito de consumo con tasas de morosidad notablemente bajas para la región.⁴⁷ Su capacidad para extraer un ingreso promedio por cliente de 80 USD, frente a costos de servicio mínimos, es un testimonio de la eficiencia operativa lograda a través de la automatización inteligente.⁴⁸

Revolut: La super-app financiera global

Revolut, con una valoración de 45 mil millones de dólares, representa el modelo de expansión agresiva y diversificación de producto.⁴⁷ Con presencia en más de 30 países y 50 millones de clientes, la plataforma utiliza IA para gestionar cuentas multi-divisa, trading de criptomonedas y servicios de gestión de gastos en una interfaz unificada.⁴⁸ En 2023, la empresa reportó ingresos de 2.2 mil millones de dólares y beneficios récord, superando las dudas iniciales sobre la rentabilidad de los

neobancos.⁴⁹ Su éxito reside en la agilidad para lanzar productos financieros complejos —como el staking de cripto o planes de seguros personalizados— utilizando modelos predictivos para anticipar la demanda del mercado.⁴⁷

Infraestructura de pagos: Stripe y Square

Más allá de los bancos digitales, las Fintech de infraestructura como Stripe y Square han redefinido el comercio global mediante APIs simples y seguridad robusta. Stripe, operando en 46 países, utiliza modelos de IA para la prevención de fraudes y la optimización de las tasas de autorización de pagos, sirviendo desde startups hasta empresas de la lista Fortune 500.⁵⁰ Por su parte, Square (Block) ha integrado servicios de préstamos para comerciantes (*Square Capital*) que utilizan datos de ventas en tiempo real para evaluar el riesgo crediticio, eliminando la necesidad de garantías tradicionales y acelerando el crecimiento de las pequeñas empresas.⁵⁰

Conclusiones y prospectiva hacia la segunda mitad de la década

El análisis exhaustivo de los métodos estadísticos y la inteligencia artificial en el sector Fintech revela una industria en su fase de madurez técnica. La convergencia de datos estandarizados bajo el ISO 20022, la potencia computacional de herramientas basadas en GPU como JAX, y la sofisticación de modelos de lenguaje y aprendizaje por refuerzo han creado un ecosistema financiero que es, por primera vez en la historia, verdaderamente predictivo y proactivo.⁷

La inteligencia artificial no es simplemente una herramienta añadida a las finanzas; es el nuevo sustrato sobre el cual se construye la economía del siglo XXI. Las

plataformas que logren integrar de manera fluida la precisión estadística con la empatía hacia el usuario y la responsabilidad ética serán las que definan el panorama financiero de las próximas décadas.¹

Conclusión

La presente investigación ha permitido trazar un puente robusto entre el rigor de los métodos estadísticos clásicos y la capacidad adaptativa de la inteligencia artificial, aplicados a un ecosistema tan volátil y complejo como el de las criptomonedas y las Finanzas Descentralizadas (DeFi). A lo largo de este estudio, se han validado tres pilares fundamentales que marcarán el futuro del sector:

1. Superación de la Eficiencia de Mercado

Se ha demostrado que los modelos lineales tradicionales resultan insuficientes para capturar la naturaleza estocástica y de "colas pesadas" de los criptoactivos. La integración de redes neuronales recurrentes (como las LSTM) y algoritmos de Gradient Boosting ha permitido identificar patrones de microestructura de mercado que antes eran invisibles, logrando una precisión predictiva superior en entornos de alta frecuencia.

2. Gestión de Riesgos en Ecosistemas DeFi

La aplicación de modelos de aprendizaje por refuerzo (*Reinforcement Learning*) en protocolos DeFi ha revelado una capacidad inédita para optimizar el *yield farming* y mitigar el riesgo de liquidación. La inteligencia artificial no solo actúa como una herramienta de rentabilidad, sino como un mecanismo de seguridad algorítmica capaz de anticipar crisis de liquidez antes de que se propaguen por la cadena de bloques.

3. Democratización y Transparencia del Dato

Uno de los hallazgos más significativos es la sinergia entre la transparencia del *on-chain data* y el procesamiento masivo de datos. A diferencia de las finanzas tradicionales, el análisis estadístico en cripto se beneficia de una fuente de verdad pública y auditável, lo que permite que los modelos de IA sean más explicables y

menos dependientes de intermediarios.

La transición hacia un sistema financiero descentralizado no es solo un cambio tecnológico, sino una evolución matemática. La inteligencia artificial no sustituye el juicio estadístico, sino que lo potencia para navegar en un mercado que nunca duerme y que se expande de forma exponencial.

La investigación concluye que la integración de la Inferencia Bayesiana dentro de arquitecturas de Aprendizaje por Refuerzo (Bayesian Reinforcement Learning) resuelve uno de los desafíos más críticos en las finanzas descentralizadas: el equilibrio entre exploración y explotación en entornos de alta incertidumbre. Mientras que un agente de RL convencional puede incurrir en riesgos excesivos al buscar políticas óptimas, un Agente Bayesiano utiliza distribuciones de probabilidad a posteriori para modelar la incertidumbre del entorno.

Mediante el uso de Muestreo de Thompson o Redes Neuronales Bayesianas, el sistema evalúa no solo el retorno esperado de una estrategia de liquidez o trading, sino también la varianza de esa predicción. Esto permite una gestión de capital dinámica donde el agente reduce automáticamente su exposición cuando la incertidumbre del modelo aumenta, permitiendo que los protocolos DeFi operen bajo una lógica de seguridad proactiva. En última instancia, esta convergencia transforma a los algoritmos de cajas negras en sistemas de decisión estadística capaces de autogestionar el riesgo en tiempo real.

Bibliografía

1. Huaranga, J. (2017). Distribución asintótica de los estimadores MCO en una regresión lineal con variables explicativas que siguen procesos estocásticos strong-mixing y tendencia. (2018). *Pesquimat*, 20(2), 65-83. <https://doi.org/10.15381/pes.v20i2.14516>
2. Jáuregui Iparraguirre, P. K. (2024). El Impacto del Gobierno Digital en la Modernización del Estado: Revisión Sistemática. *Revista Científica Visión De Futuro*, 29(1). Recuperado a partir de <https://revistacientifica.fce.unam.edu.ar/index.php/visiondefuturo/article/view/848>
3. Fernández, R.A., & Ruff, T.E. (2017). Estimación del multiplicador keynesiano del turismo internacional en Argentina. *Estudios y perspectivas en turismo*, 26(2), 248-266
4. Damgaard, C. (2021). Adaptive management plans rooted in quantitative ecological predictions of ecosystem processes: putting monitoring data to practical use. *Environmental Conservation*, 49(1), 27-32. <https://doi.org/10.1017/s0376892921000357>
5. Montero Granados, R. (2016). *Modelos de regresión lineal múltiple. Documentos de Trabajo en Economía Aplicada*. Universidad de Granada. España
6. Camilo, J., & Ossa, K. (2024). Análisis sobre el uso de las plataformas digitales por los clientes, en los procesos bancarios. (2024). *Ingeniería: Ciencia, tecnología E innovación*, 11(1), 135-

152. <https://doi.org/10.26495/mctajh44>
7. Espinosa-Zúñiga, Javier Jesús. (2020). Aplicación de algoritmos Random Forest y XGBoost en una base de solicitudes de tarjetas de crédito. *Ingeniería, investigación y tecnología*, 21(3), 00002. Epub 02 de diciembre de 2020. <https://doi.org/10.22201/fi.25940732e.2020.21.3.022>
 8. Siddique, A. B., Munshi, T. A., Rakin, N. I., Hashan, M., Chnapa, S. S., & Jahan, L. N. (2025). Application of supervised machine learning and unsupervised data compression models for pore pressure prediction employing drilling, petrophysical, and well log data. *Scientific reports*, 15(1), 24706. <https://doi.org/10.1038/s41598-025-89199-3>
 9. Coutin Marie, G. (2007). Utilización de modelos ARIMA para la vigilancia de enfermedades transmisibles. *Revista Cubana de Salud Pública*, 33(2), 1-11. Recuperado de <http://scielo.sld.cu/pdf/rcsp/v33n2/spu12207.pdf>
 10. Ercan S. (2023). Comparación de la métrica Sigma calculada con tres métodos de estimación del sesgo en 33 magnitudes químicas y 26 de inmunoensayo. *Advances in laboratory medicine*, 4(3), 246–257. <https://doi.org/10.1515/almed-2023-0095>
 11. Martínez, C., (2013). Un análisis del aporte de estimadores GMM en sistemas y diferencias a la estimación de ecuaciones dinámicas en economía. *Cuadernos del CIMPAGE*, (15), 19-31
 12. Orihuela, E., Javier Soto, A., Bendezú Jiménez, H., & Achata Huayhuas, L. (2023). Un Modelo Vectorial Autorregresivo (VAR) aplicado a las exportaciones de materias primas (oro y cobre) y la balanza de pagos: el

caso peruano (2012- 2022). *Compendium: Cuadernos De Economía Y Administración*, 10(1), 63-75.

<https://doi.org/10.46677/compendium.v10i1.1167>

13. Támara-Ayús, A. L., Vargas-Ramírez, H., Cuartas, J. J., & Chica-Arrieta, I. E. (2019). Regresión logística y redes neuronales como herramientas para realizar un modelo Scoring1. *Revista Lasallista de Investigación*, 16(1), 187-200. <https://doi.org/10.22507/rli.v16n1a5>
14. Campo. J., & Sarmiento, V. (2011). Un modelo de corrección de errores para la relación entre el consumo de energía y el PIB en Colombia (1970-2009). *Finanzas y Política Económica*, 3(1), 59-70. Recuperado de <https://dialnet.unirioja.es/descarga/articulo/4033170.pdf>
15. Tello, M. (2017). *Análisis de equilibrio general: Modelos y aplicaciones para países en desarrollo*. Lima: Pontificia Universidad Católica del Perú
16. Stiglitz, J. (2017). Hacia una sociedad justa. New York: Prensa de la Universidad de Columbia
17. Landa, N. (11 octubre, 2021). La maldición de la dimensionalidad. *Medium*. <https://medium.com/@nicolasarrioja/la-maldici%C3%B3n-de-la-dimensionalidad-f7a6248cf9a>
18. S. Ponnusamy and P. Gupta. (2024). "Scalable Data Partitioning Techniques for Distributed Data Processing in Cloud Environments: A Review," in *IEEE Access*, 12, 26735-26746. <https://doi.org/10.1109/ACCESS.2024.3365810>
19. Abdelaziz, A., Mahmoud, AN, Santos, V. y Freire, MM (2025). Integración de redes convolucionales temporales con optimización metaheurística para la predicción precisa de defectos de software. *PloS one*, 20 (5), e0319562. <https://doi.org/10.1371/journal.pone.0319562>

20. Chávez Lazo, I. B., & Burgos Zavaleta, V. F. J. (2021). Factores económicos externos en el crecimiento de la economía peruana: Un modelo vector autorregresivo (VAR). *Quipukamayoc*, 29(61), 37-46. <https://doi.org/10.15381/quipu.v29i61.21628>
21. Tejera, G., & Marzoa, M. (2024). *Detección de defectos estructurales en saneamiento usando redes neuronales* [Tesis de grado]. Universidad de la República Uruguay
22. G. Haldane, A., y E. Turrell, A. (2018). Un modelo interdisciplinario para la macroeconomía. *Revista de Economía Institucional*, 21(40), 69–110. <https://doi.org/10.18601/01245996.v21n40.03>
23. Apellido, N. N. (año). *Reporte del sistema nacional de pagos y del sector Fintech en Perú*. Banco Central de Reserva del Perú (BCRP). <https://www.bcrp.gob.pe/docs/Publicaciones/reportes-del-sistema-nacional-de-pagos/2025/marzo/rspf-marzo-2025.pdf>
24. Rendón, A. H., Gómez, H. F., & Alonso Botero García, J. (2011). Los modelos DSGE: una respuesta de la discusión macroeconómica. *Estudios económicos*, 28(57), 59–78. <https://doi.org/10.52292/j.estudecon.2011.773>
25. Lizarazu Alanez, E. (2006). La macroeconomía IS-LM. Una retrospección teórica estilizada. *Investigación económica*, 65(256), 103-129
26. Muth, M., Lingenfelder, M. y Nufer, G. (2025). La aplicación del aprendizaje automático para la predicción de la demanda en condiciones de volatilidad macroeconómica: una revisión sistemática de la literatura. *Manag. Rev. Q.*, 75, 2759–2802 (2025). <https://doi.org/10.1007/s11301-024-00447-8>
27. Blanchard, O. (2016). ¿Tienen futuro los modelos DSGE?. *Revista de Economía Institucional*, 18(35), 39–46. <https://doi.org/10.18601/01245996.v18n35.03>
28. Consejo Económico y Social España (2025). *Economía, Trabajo Y Sociedad Memoria Sobre La Situación Socioeconómica Y Laboral España 2024*. Huertas: Consejo

Económico y Social.

29. Cerquera Losada, O. H., Manrique Parra, S., & Ovalle Díaz, A. L. (2021). Análisis teórico de los modelos de agentes heterogéneos y el Covid-19. *Civilizar*, 21(41), 1-13. <https://doi.org/10.22518/jour.ccsn/2021.2a01>
30. Paniagua, P. (2023). La complejidad que desafía a la macroeconomía. *Cambridge Journal of Economics*, 47(3), 575–592, <https://doi.org/10.1093/cje/bead002>
31. Ministerio de Economía y Finanzas Perú. (2019, 31 de enero). *Competitividad y Productividad: 9 Objetivos Prioritarios para impulsar y consolidar el crecimiento económico del país* [Comunicado de prensa]. https://www.mef.gob.pe/es/?option=com_content&language=es-ES&Itemid=101108&view=article&catid=100&id=5892&lang=es-ES
32. Torres Gutiérrez, J. J. (2023). La transmisión de la política monetaria al mercado inmobiliario español. *Revista De Estudios Empresariales. Segunda Época*, 2, 127-164. <https://doi.org/10.17561/ree.n2.2023.7914>
33. Sarián González, M. (2024). Integración de Inteligencia Artificial en la Inteligencia de Negocio: potencial de los datos no estructurados para la toma de decisiones estratégicas. *UCV-Scientia*, 16(2), 48-55. <https://doi.org/10.18050/revucv-scientia.v16n2a5>
34. Loaiza, N. (2008). Causas y consecuencias de la informalidad en el Perú. *Estudios Económicos* BCRP, 15(3), 43-64. Recuperado de <https://www.bcrp.gob.pe/docs/Publicaciones/Revista-Estudios-Economicos/15/Estudios-Economicos-15-3.pdf>.
35. Barrios, J., Martín, L., Escobar, J., Peña, W., & Leslie, J. (2021). *Nowcasting para predecir actividad económica en tiempo real: los casos de Belice y El Salvador*. Washington: BID
36. Chan, W., Gai, K., Yu, J. y Zhu, L. (2025). Identidades autosuficientes en

- educación asistidas por blockchain: un estudio. *Blockchains* , 3 (1), 3. <https://doi.org/10.3390/blockchains3010003>
37. Kim S, Zhang A, Liao R, Zheng W, Hu Z, Sun Z. (2022). Muestreo de aplicaciones de ciudades inteligentes basadas en blockchain entre Corea del Sur, Estados Unidos y China. *Journal of Smart Cities and Society*. 1(1), 53-70. <https://doi.org/10.3233/SCS-210120>
38. Pabón Trujillo , H., Carlos Castillo, J., Dayana Rangel, A., Fabián Patiño, O., Angarita Bautista, R. E., & Cáceres Cárdenas, J. Z. (2025). El Impacto Global de la IA en la Seguridad en el Trabajo, Oportunidades y Desafíos para el Futuro del Trabajo. *Ciencia Latina Revista Científica Multidisciplinar*, 9(2), 7500-7513. https://doi.org/10.37811/cl_rcm.v9i2.17476
39. Maldonado Benítez, VM, Morales Matamoros, O., y Moreno Escobar, JJ (2025). Hacia Ciudades Resilientes: Revisión Sistemática de la Literatura sobre el Uso de IA para Optimizar la Captación de Agua y Mitigar la Escasez. *Water* , 17 (13), 1978. <https://doi.org/10.3390/w17131978>
40. Aguirre, U. (2017). Recursos naturales y desarrollo: Los dilemas de una relación crítica. *Serie Documentos De Trabajo*, 1-100. Recuperado de https://www.ucm.es/data/cont/media/www/pag-82472/DT39_RafaelAguirre.pdf
41. Concha, J.R., & Pichler, B. (2010). Crecimiento De La Economía China Y Su Impacto En Su Estratégica Energética. *Estudios Gerenciales*, 26(117), 131-144. [https://doi.org/10.1016/S0123-5923\(10\)70138-8](https://doi.org/10.1016/S0123-5923(10)70138-8)
42. Morales-Sáenz, FI, Medina-Quintero, JM, y Reyna-Castillo, M. (2024). Más allá de la protección de datos: Explorando la convergencia entre la ciberseguridad y el desarrollo sostenible en las empresas. *Sustainability* , 16 (14), 5884. <https://doi.org/10.3390/su16145884>

43. Thompson, S. (2023). Análisis estratégico de la transición a la electricidad renovable: ¿Energía para el mundo sin emisiones de carbono? *Energies* , 16 (17), 6183. <https://doi.org/10.3390/en16176183>
44. Diez, H., Pérez, M., Pérez, F. y Montes, M. (2012). Medición del desempeño y éxito en la dirección de proyectos. Perspectiva del Manager público. *Revista EAN*, (73), 60-79. <http://dx.doi.org/10.21158/01208160.n73.2012.586>
45. Obaya, M., & Asinsten, J. (2025). *Oportunidades y desafíos para América Latina y el Caribe en el nuevo contexto global de la industria del litio y la transición hacia la electromovilidad*. Washington: Banco Interamericano de Desarrollo
46. Guía Minera de Chile. (s/f). Mercado del litio 2025-2026: entre la sobreoferta, la volatilidad y el reposicionamiento estratégico. *Guía Minera de Chile*. <https://www.guiaminera.cl/mercado-del-litio-2025-2026-entre-la-sobreoferta-la-volatilidad-y-el-reposicionamiento-estrategico/>
47. Moshawrab, M., Adda, M., Bouzouane, A., Ibrahim, H. y Raad, A. (2024). Garantizar el aprendizaje federado: enfoques, mecanismos y oportunidades. *Electrónica* , 13 (18), 3675. <https://doi.org/10.3390/electronics13183675>
48. Guix, R. (2023). El impacto de la Inflation Reduction Act en las relaciones transatlánticas. *Real Instituto Elcano*. Recuperado de <https://media.realinstitutoelcano.org/wp-content/uploads/2023/04/el-impacto-de-la-inflation-reduction-act-en-las-relaciones-transatlanticas-real-instituto-elcano.pdf>
49. Giudice Baca, V., & Zapata Tito, R. (2020). Neobancos Nuevo Reto en el Mercado Financiero Peruano. *Newman Business Review*, 6(1), 105–125. <https://doi.org/10.22451/3006.nbr2020.vol6.1.10048>
50. Fondo Monetario Internacional (FMI). (2024). *Perspectivas de la economía mundial*.

Washington: FMI

51. Angulo-Bustinza, H. & Lis-Gutiérrez, J. (2023). Comercio y crecimiento económico inclusivo: China y América Latina (2004-2021). *Retos Revista de Ciencias de Administración y Economía*, 13(26), 309-323.
<https://doi.org/10.17163/ret.n26.2023.08>
52. García, G., & Baeza, R. (2016). Las políticas monetarias heterodoxas en el contexto de la Gran Recesión. Un comparativo entre el Sistema de la Reserva Federal y el Banco Central Europeo. (2018). *Análisis Económico*, 31(77), 177-204. <https://analisiseconomico.azc.uam.mx/index.php/rae/article/view/55>
53. Al Omoush, K., Lassala, C., & Ribeiro-Navarrete, S. (2025), "The role of digital business transformation in frugal innovation and SMEs' resilience in emerging markets". *International Journal of Emerging Markets*, 20(1), 366-386.
<https://doi.org/10.1108/IJEM-12-2022-1937>
54. Ortiz, Manuel S., & Fernández-Pera, M. (2018). Modelo de Ecuaciones Estructurales: Una guía para ciencias médicas y ciencias de la salud. *Terapia psicológica*, 36(1), 51-57. <https://dx.doi.org/10.4067/s0718-48082017000300047>
55. Arroyo-Menéndez, M., Gutiérrez-Láiz, N., y Criado-Quesada, B. (2022). La digitalización de las personas mayores: análisis de la confluencia múltiple de las brechas sociales y espaciales. *Land*, 11 (6), 953.
<https://doi.org/10.3390/land11060953>
56. Finch, H. (2024). Comparación de métodos para sintetizar resultados de investigaciones previas con el fin de obtener valores previos para el modelado bayesiano de ecuaciones estructurales. *Psych*, 6 (1), 45-88.
<https://doi.org/10.3390/psych6010004>

De esta edición de “*Métodos estadísticos con inteligencia artificial aplicados a criptomonedas y finanzas descentralizadas*”, se terminó de editar en la ciudad de Colonia del Sacramento en la República Oriental del Uruguay el 15 de diciembre de 2025

Editorial Mar Caribe

MÉTODOS ESTADÍSTICOS CON INTELIGENCIA ARTIFICIAL APLICADOS A CRIPTOMONEDAS Y FINANZAS DESCENTRALIZADAS

Escrito por:

**Carolina Montes Lizárraga
Remo Choquejahua Acero
Enrique Gabriel Pongo Mendo
Luis Centeno Ramírez
Luis Enrique Ramirez Milla
Joaquin Alvarez Carrillo
Daisy Mestas Yucra**

ISBN: 978-9915-698-55-7



9 789915 698557