

Evaluación de la resiliencia de modelos predictivos basados en IA en contextos de crisis económicas: una revisión sistemática

Evaluating the resilience of AI-based predictive models in the context of economic crises: a systematic review

Recibido: 28/05/2025 - Aceptado: 12/10/2025

Jorsi Ericson Joel Balcázar Gallo

<https://orcid.org/0000-0002-8378-0609>

jbalcazarg@unca.edu.pe

Universidad Nacional Ciro Alegría. Huamachuco, Perú

Javier Valdiviezo Miranda

<https://orcid.org/0000-0003-4767-9738>

jvaldiviezom@ucvvirtual.edu.pe

Universidad César Vallejo. Trujillo, Perú

Leandro Adolfo Pérez Cruz

<https://orcid.org/0009-0004-6171-4979>

leandro.perez@upn.pe

Universidad Privada del Norte. Trujillo, Perú

Cecilia Maria Madrid Villarreyes

<https://orcid.org/0000-0002-7437-8941>

cmadridv1@upao.edu.pe

Universidad Privada Antenor Orrego. Trujillo, Perú

Resumen

En un contexto de creciente incertidumbre económica, comprender cómo las crisis impactan la resiliencia de los modelos predictivos basados en inteligencia artificial (IA) es fundamental. Este artículo tiene como objetivo evaluar de forma integral el efecto de diversas crisis económicas en la efectividad y adaptabilidad de estos modelos. Para ello, se realizó una revisión sistemática de 29 artículos indexados en Scopus, publicados entre 2020 y 2025. La selección de estudios consideró criterios estrictos de inclusión, priorizando investigaciones revisadas por pares que abordaran problemáticas vinculadas a crisis financieras, sanitarias y sociales, descartando aquellos que no cumplieran con dichos requisitos. Los resultados revelan que los modelos que incorporan variables macroeconómicas y contextuales presentan mayor robustez y precisión, destacándose por su capacidad para adaptarse a escenarios de alta volatilidad. Además, se identificó que la resiliencia de estos modelos depende no solo de su solidez técnica, sino también de su sensibilidad ante cambios en los entornos económicos. En conjunto, estos hallazgos ofrecen una comprensión más profunda de los mecanismos que fortalecen la estabilidad predictiva durante crisis, proponiendo un camino para el desarrollo de modelos de IA más adaptativos y resilientes, capaces de anticipar con mayor precisión los efectos de futuras perturbaciones económicas.

Palabras clave: crisis económicas, inteligencia artificial, resiliencia.

Abstract

In a context of growing economic uncertainty, understanding how crises impact the resilience of artificial intelligence (AI)-based predictive models is fundamental. This article aims to comprehensively assess the effect of various economic crises on the effectiveness and adaptability of these models. To this end, a systematic review of 29 articles indexed in Scopus and published between 2020 and 2025 was conducted. The selection of studies considered strict inclusion criteria, prioritizing peer-reviewed research that addressed issues related to financial, health, and social crises, discarding those that did not meet these requirements. The results reveal that models

that incorporate macroeconomic and contextual variables present greater robustness and accuracy, standing out for their ability to adapt to highly volatile scenarios. Furthermore, it was identified that the resilience of these models depends not only on their technical soundness but also on their sensitivity to changes in the economic environment. Together, these findings offer a deeper understanding of the mechanisms that strengthen predictive stability during crises, proposing a path for the development of more adaptive and resilient AI models capable of more accurately anticipating the effects of future economic shocks.

Keywords: economic crises, artificial intelligence, resilience.

Introducción

La inteligencia artificial (IA) ha transformado profundamente el panorama de la predicción económica, al proporcionar herramientas avanzadas para analizar y anticipar las fluctuaciones del mercado. Sin embargo, la efectividad de los modelos predictivos basados en IA enfrenta retos particularmente complejos en contextos de crisis económicas, donde las variables macroeconómicas sufren cambios abruptos. Por ello, resulta fundamental estudiar cómo las características específicas de estas crisis afectan la resiliencia de dichos modelos, con el fin de mejorar su capacidad de adaptación y precisión. En estos escenarios de alta volatilidad, los algoritmos y metodologías deben ajustarse para garantizar estimaciones confiables, como han señalado trabajos recientes (Amamou et al., 2024).

Uno de los principales desafíos de aplicar IA en la predicción económica durante crisis radica en la interdependencia no lineal entre variables, lo que aumenta la complejidad y eleva el margen de error en las predicciones (Amamou et al., 2024). Esta situación subraya la importancia de investigar cómo la irrupción repentina o la prolongación de una crisis condiciona la adaptabilidad de los modelos. En este sentido, la literatura destaca que las crisis no solo distorsionan indicadores económicos tradicionales, sino que también introducen factores adicionales, como las percepciones de riesgo de los inversionistas (Addisu & Bang, 2022).

Además, se ha planteado que combinar técnicas de aprendizaje automático con enfoques macroeconómicos puede ofrecer perspectivas novedosas para evaluar la resiliencia de los modelos predictivos en situaciones críticas (Amamou et al., 2024). Sin embargo, aún existe un vacío importante en la investigación respecto a un enfoque sistemático que articule distintos tipos de crisis y analice la eficacia de los modelos de IA frente a cada uno.

En este contexto, la resiliencia de los modelos predictivos apoyados en IA se ha convertido en un área crucial, especialmente frente a crisis que afectan directamente los mercados financieros. Analizar cómo las particularidades de estas crisis inciden en la eficacia de los modelos es esencial para comprender su nivel de adaptación y mejorar su desempeño bajo condiciones adversas. En los últimos años, varias investigaciones han aportado avances relevantes en este campo, fortaleciendo el desarrollo de modelos de IA más resilientes en economía.

Un aporte destacado es el de Kyriakou et al. (2023), quienes diseñaron una metodología para anticipar la resiliencia de empresas en episodios críticos. Utilizando datos históricos gubernamentales, su estudio permitió optimizar programas de estímulo económico y resaltó el papel de la IA en la identificación de organizaciones vulnerables. De forma complementaria, Evgrafova et al. (2023) exploraron la resiliencia empresarial durante la pandemia de COVID-19, demostrando que la responsabilidad social corporativa potencia la capacidad de las organizaciones para afrontar choques sistémicos, implicando que los modelos predictivos deben integrar variables cualitativas.

Por otro lado, Wang & Li (2022) analizaron los determinantes de la resiliencia económica regional, evidenciando que el impacto de las crisis varía notablemente según el contexto geográfico y estructural. Este hallazgo resalta la necesidad de que los modelos incorporen factores regionales para anticipar resultados de manera más precisa en distintos entornos económicos.

En conjunto, estos estudios profundizan en cómo las crisis condicionan la eficacia de los modelos de IA y ofrecen bases sólidas para futuras investigaciones orientadas a desarrollar estrategias que integren tanto variables macroeconómicas como cualitativas.

No obstante, persisten vacíos importantes en la literatura. Por ejemplo, Puli et al. (2024) elaboraron un análisis sobre técnicas de aprendizaje automático para la predicción de crisis bancarias en India, enfatizando la necesidad de adaptar modelos a las particularidades del sistema financiero local. Sin embargo, no abordaron cómo distintos tipos de crisis afectan la eficacia de estos modelos, evidenciando aún un déficit en la comprensión de esta relación.

De igual modo, Iuga & Mihalciuc (2020) señalaron que las crisis del siglo XXI han tenido efectos devastadores en el crecimiento económico, generando dudas sobre la capacidad actual de los modelos para anticipar y responder a tales eventos. Por su parte, Reier & Garay (2021) discutieron el papel de la transformación digital y la IA en los negocios durante crisis, aunque advirtieron la limitada exploración sobre cómo optimizarlas específicamente ante crisis financieras.

Estos vacíos justifican la realización de estudios que examinen en profundidad la relación entre las características de las crisis y la resiliencia de los modelos predictivos basados en IA. Por tanto, el propósito de este artículo es analizar cómo factores como la gravedad, duración y naturaleza de los eventos económicos afectan la eficacia de estos modelos, con el fin de orientar propuestas metodológicas más robustas y adaptables.

Metodología

Se aplicó el método PRISMA 2020 (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) para asegurar la transparencia y trazabilidad del proceso de revisión. Se plantearon las siguientes preguntas de investigación: ¿Cuáles características específicas de las crisis económicas resultan más relevantes para la resiliencia de los modelos predictivos basados en inteligencia artificial? ¿De qué manera han respondido estos modelos de IA a diferentes tipos de crisis económicas en estudios previos? ¿Qué metodologías se han empleado para evaluar la efectividad de los modelos predictivos en contextos críticos?

La búsqueda bibliográfica se realizó entre enero y marzo de 2024, consultando las bases de datos Scopus, Web of Science (WoS), SciELO y Latindex. Se consideraron publicaciones revisadas por pares, en inglés y español, correspondientes al período 2019-2024. Para ello, se emplearon operadores booleanos con combinaciones de palabras clave tales como: (“predictive model resilience” AND “artificial intelligence” AND “economic crisis”) OR (“AI-based prediction” AND “financial resilience”) OR (“machine learning models” AND “crisis forecasting”) NOT (“non-economic applications” OR “education” OR “medicine only”).

Los resultados fueron exportados a Mendeley, donde se realizó un control automático y manual para eliminar duplicados. La selección se llevó a cabo en varias etapas: revisión de títulos y resúmenes, exclusión de estudios irrelevantes o carentes de rigor metodológico, y evaluación de texto completo conforme a criterios de inclusión y exclusión (ver Tabla 1).

Se priorizaron los artículos con enfoques empíricos, metodológicos o mixtos que evaluaran la resiliencia o desempeño de modelos predictivos de IA en contextos de crisis económicas, financieras, sanitarias o geopolíticas.

Tabla 1
Criterios de inclusión y exclusión

Criterios de Inclusión	Criterios de Exclusión
Artículos revisados por pares sobre crisis económicas e IA	Estudios sobre aplicaciones no económicas de la IA
Investigaciones con metodologías cuantitativas o cualitativas	Trabajos sin rigor científico ni metodológico
Estudios con datos empíricos en distintos contextos de crisis	Publicaciones sin texto completo o duplicadas

Este enfoque sistemático garantizó una revisión con evidencia sólida y relevante, facilitando la comprensión de cómo las crisis económicas afectaron la eficacia de los modelos predictivos basados en inteligencia artificial.

Durante la fase de identificación, se localizaron 450 artículos en Scopus, y se obtuvieron 250 registros adicionales en otras bases de datos indexadas: Web of Science (65), SciELO (28) y Latindex (157).

En la etapa de eliminación de duplicados, se detectaron coincidencias entre las diferentes bases de datos, por lo que se eliminaron 350 registros repetidos, quedando 350 artículos únicos para la revisión inicial.


Durante el proceso de cribado (screening), se revisaron títulos y resúmenes, descartándose 150 artículos que no abordaban directamente la resiliencia de los modelos predictivos ni cumplían con el rigor metodológico exigido.

En la evaluación de elegibilidad, se analizaron a profundidad 200 textos completos, rechazándose 171 estudios por centrarse en aplicaciones no económicas de la IA, presentar deficiencias en validez científica o metodológica, o por falta de acceso al texto completo.

Finalmente, en la fase de inclusión se seleccionaron 29 artículos que cumplieron con todos los criterios de calidad, pertinencia y coherencia temática, los cuales fueron analizados detalladamente para la elaboración de esta revisión sistemática (véase Figura 1).

Figura 1

Aplicación del método PRISMA



Resultados

Tabla 2

Comparativa resiliencia de modelos IA en crisis económicas

Autor	Tipo de crisis económica	Variables clave	Método predictivo	Relación con resiliencia	Tipo de estudio	Variable	Tendencia metodológica / mejora observada
Gifu	Crisis financiera global (2007–2008)	Quiebra bancaria, recesión, colapso del crédito	IA aplicada al e-learning y modelos predictivos comparativos	Evalúa cómo las crisis afectan la precisión y resiliencia de modelos	Cuantitativo	Sí	Incorporación de datos de crisis mejora precisión predictiva (↑ resiliencia)

Abdullayev et al.	Crisis financieras generales	Indicadores macroeconómicos de riesgo, volatilidad	Redes neuronales bayesianas con metaheurísticas	Analiza resiliencia al incluir incertidumbre macroeconómica	Cuantitativo	Sí	Mejora significativa en robustez del modelo ante volatilidad (↑ resiliencia)
Li	Crisis empresariales (insolvencia)	Factores financieros y no financieros de empresas	Reconocimiento de patrones + IA	Integra factores de crisis para estabilidad del modelo	Cuantitativo	Sí	La integración de variables externas reduce error y mejora estabilidad
Korol & Fotiadis	Crisis globales, COVID-19, guerra Ucrania	Inflación, desempleo, tasas de interés	Modelos de IA para bancarota de hogares	Examina resiliencia frente a choques múltiples	Cuantitativo	Sí	IA mantiene precisión en entornos con alta incertidumbre macroeconómica
Kotan et al.	Crisis económicas en Turquía (2021)	Noticias financieras, inflación, devaluación	NLP + Machine Learning	Evalúa capacidad resiliente ante choques abruptos	Cuantitativo	Sí	Text mining mejora detección temprana de crisis (↑ resiliencia)
Kumar et al.	Crisis financieras empresariales	Solvencia, insolvencia, deterioro financiero	Bird Swarm Algorithm + redes neuronales difusas	Mide resiliencia del modelo frente a colapso empresarial	Cuantitativo	Sí	El enfoque híbrido mejora 20–30% la estabilidad del modelo
Bhattacharya et al.	Crisis en PYMES	Tasas de interés, volatilidad cambiaria, financiamiento	Optimización Grey Wolf + Sparse Autoencoder	Explica cómo crisis reducen estabilidad predictiva	Cuantitativo	Sí	Modelos ajustados con variables contextuales ↑ precisión y resiliencia
Reis et al.	Crisis económicas y devaluaciones	Eventos externos textuales, precios agrícolas	Integración de texto + series temporales	Combina shocks externos con predicción de precios	Cuantitativo	Sí	Datos textuales amplían capacidad adaptativa del modelo
Tamasiga	Crisis económicas, climáticas y sanitarias	Disrupciones globales, inseguridad alimentaria	Bibliometría + Big Data + IA	Explora resiliencia desde visión sistémica	Cualitativo (bibliométrico)	No	Identifica brechas y orienta futuras integraciones empíricas
Yang et al.	Crisis económicas, pandemias, shocks sociales	Desempleo, rupturas estructurales, volatilidad	ARIMA, VARIMA, Transformers	Evalúa resiliencia bajo crisis multidimensionales	Cuantitativo	Sí	Comparación empírica muestra que modelos híbridos (TFT) ↑ resiliencia
Yu & Chang	Crisis financieras globales (2007–2008)	Inflación, PPI, CPI, riesgo macroeconómico	Red neuronal + Copula-GARCH + Mean-CVaR	Integra factores macroeconómicos para robustecer resiliencia	Cuantitativo	Sí	Integración de riesgos macro → 25% ↑ estabilidad en crisis

Tabla 3
Síntesis derivada del análisis

Dimensión analizada	Frecuencia (n)	Porcentaje (%)	Conclusión interpretativa
Artículos con enfoque cuantitativo	10	91 %	Predominan modelos empíricos basados en IA, econometría o simulaciones.
Artículos cualitativos / bibliométricos	1	9 %	Solo un caso aporta análisis teórico-conceptual sobre resiliencia.
Estudios que incorporan variables contextuales	10	91 %	Incluir factores macroeconómicos mejora notablemente precisión y estabilidad.
Modelos híbridos IA + econometría / metaheurística	7	64 %	Tendencia dominante hacia enfoques combinados más robustos.
Estudios que reportan mejora significativa en resiliencia	10	91 %	Todos los cuantitativos confirman incremento de resiliencia con contexto económico.

Tabla 4
Metodologías para evaluar modelos predictivos en crisis

Autor(es) y Año	Tipo de crisis	Metodología predictiva	Evaluación de efectividad	Relación con resiliencia	Uso de variables contextuales	Tipo de metodología dominante
Ben Ayed & Ben Hassen	Crisis financiera COVID-19	Modelos VaR: RiskMetrics, GARCH/FIGARCH, SPLINE-GARCH, EVT	Backtesting de pérdidas, cumplimiento Basel II/2.5	Evalúa robustez ante volatilidad extrema	No	Econométrico
Chumachenko et al.	Guerra + COVID-19 (Italia)	XGBoost (ML)	Validación retrospectiva, exactitud 86.03% casos / 96.29% muertes	Prueba capacidad del modelo bajo shock bélico-sanitario	Sí (contexto bélico-sanitario)	Machine Learning
Liu & Shen	Crisis de mercado de carbono	EWT-GRU, comparado con ARIMA, BPNN, GRU	Métricas MAE, MSE, RMSE; superioridad frente a métodos clásicos	Mayor precisión en series no lineales durante crisis	No	Deep Learning
Kim et al.	Crisis sanitaria COVID-19	CNN + transfer learning + data augmentation	Métricas de exactitud, robustez y generalización	Detecta limitaciones de CNN y mejoras para resiliencia	No	Deep Learning
Lezcano et al.	Crisis sanitaria COVID-19	ARIMA, SIR, RF, NN, KNN	Comparación de desempeño en predicciones a 30 días	Analiza adaptabilidad de modelos epidemiológicos y ML	Sí (variables epidemiológicas y territoriales)	Machine Learning / Híbrido
Manousiadis & Gaki	Crisis económica COVID-19 en EE. UU.	Árboles de decisión, redes neuronales	Comparación entre clasificadores e interpretación de modelos	Estudia resiliencia regional en escenarios de desastre	Sí (contexto regional y económico)	Machine Learning
Ramakrishnaiah et al.	Crisis de salud digital	EHR-ML framework (pipeline de IA)	Validación cruzada, ajuste de hiperparámetros	Optimiza modelos para reducir sesgos en crisis	No	Deep Learning / Framework

Wu et al.	Crisis sanitaria COVID-19	Modelos multimodales (datos clínicos + imagen)	Validación externa, precisión en mortalidad	Asegura confiabilidad bajo escenarios críticos	Sí (datos hospitalarios múltiples)	Deep Learning
Xie et al.	Crisis ambiental y económica (carbono agrícola)	LSTM optimizado con TPEBO, comparado con ARIMA y ANN	MAE, RMSE; optimización bayesiana mejora desempeño	Evalúa resiliencia de predicciones en emisiones agrícolas	Sí (variables regionales y ambientales)	Deep Learning optimizado
Xu & Shi	Crisis política/nacional	BP Neural Network, proyección optimizada	$R^2 = 0.9967$ en predicciones de riesgo político	Refuerza resiliencia institucional ante crisis	Sí (factores políticos y de seguridad nacional)	Deep Learning
Karaev & Borisova	Crisis económica (presupuestos estatales)	ML, deep learning vs. DSGE	Comparación de precisión entre modelos	Propone IA para superar fallos de modelos clásicos	Sí (contexto fiscal y macroeconómico)	Machine Learning / Deep Learning

Tabla 5
Metodologías predictivas más frecuentes

Tipo de metodología	Ejemplos	Frecuencia (n)	Porcentaje
Machine Learning tradicional (árboles, RF, XGBoost, SVM)	Chumachenko (XGBoost), Lezcano (RF), Manousiadis (DT), Karaev (ML)	4	36%
Deep Learning (ANN, CNN, LSTM, GRU, multimodal)	Liu (EWT-GRU), Kim (CNN), Wu (multimodal), Xie (LSTM), Xu (BP NN)	5	45%
Modelos econométricos/estadísticos clásicos (ARIMA, GARCH, VaR)	Ben Ayed (VaR), Lezcano (ARIMA)	2	18%
Híbridos y optimizados (IA + heurísticas o metaheurísticas)	Xie (TPEBO-LSTM), Ramakrishnaiah (EHR-ML)	ya incluidos en DL/ML, pero con optimización avanzada	—

Tabla 6
Metodologías predictivas en contextos de crisis

Autor(es) y Año	Tipo de crisis	Metodología principal	Variables contextuales consideradas	Mejora con variables contextuales	Metodología más frecuente	Relación con resiliencia
Ben Ayed & Ben Hassen (2024)	Financiera (COVID-19)	GARCH, FIGARCH, EVT	Volatilidad, tasas, shocks globales	Sí ($\approx +20\%$ precisión)	GARCH/ML	Resiliencia ante alta volatilidad
Chumachenko et al. (2023)	Guerra/sanitaria	XGBoost	Variables geopolíticas y de movilidad	Sí	ML (XGBoost)	Modelos robustos ante choques múltiples
Hamdi & Chkili (2019)	Financiera islámica	FIAPARCH-ANN	Volatilidad macroeconómica	Sí	Híbrido ML	Mejora estabilidad de predicciones
Karaev & Borisova (2025)	Económica/fiscal	RF, DNN	PIB, inflación, recaudación	Sí ($\approx +15\%$)	ML/DL	Estabilidad en entornos inestables
Kim et al. (2025)	Sanitaria (COVID-19)	CNN	Variables médicas y demográficas	Parcial (limitada)	CNN	Transfer learning mejora resiliencia

Kiranmai & Thangaraj (2024)	Financiera (cripto)	Ensemble ML	Volatilidad y sentimiento de mercado	Sí ($\approx +10\%$)	Ensemble ML	Precisión en escenarios volátiles
Lezcano et al. (2023)	Sanitaria (COVID-19)	ARIMA, NN, RF	Series epidemiológicas	Sí	ML estadístico	Valida capacidad adaptativa de modelos
Li et al. (2024)	Epidemiológica	Bayesian + RF	Variables clínicas y temporales	Sí	Ensemble Bayesiano	Alta exactitud predictiva
Liu & Shen (2020)	Climática/mercado carbono	EWT–GRU	Precio energético y carbono	Sí ($\approx +18\%$)	Deep Learning (GRU/LSTM)	Mejora predicción en volatilidad
Rodrigues et al. (2021)	Energética	SARIMA, ANN, RF	Variables de movilidad y consumo	Sí	Ensemble ML	Resiliencia energética
Manousiadis & Gaki (2023)	Económica (EE. UU.)	Árboles y NN	PIB, desempleo, densidad poblacional	Sí	ML clásico	Modelos capturan resiliencia territorial
Moraglio & Ragusa (2024)	Energética/geopolítica	Kernel & Linear Regression	Precios globales, shocks geopolíticos	Sí ($\approx +12\%$)	Regresión	Explica resiliencia de precios
Mousavimehr & Kavianpour (2025)	Climática/hídrica	SVR, RF, ANN, CNN	Factores antrópicos e hidrológicos	Sí ($\approx +25\%$)	DL (CNN)	Mejora correlación TWS–GWS
Wu et al. (2022)	Sanitaria	Multimodal ML (EHR + CXR)	Edad, comorbilidad, radiología	Sí	Multimodal ML	Resiliencia hospitalaria
Xie et al. (2024)	Climática	LSTM + Bayesian Optimization	Emisiones agrícolas regionales	Sí	DL (LSTM)	Alta precisión temporal
Xu & Shi (2025)	Política/nacional	BP Neural Network + Proyección	Factores políticos y sociales	Parcial	ML (BP)	Evalúa resiliencia nacional

Tabla 7
Análisis de tendencias actuales

Indicador	Resultado
Porcentaje de estudios que mejoran al incluir variables contextuales	87.5% (14 de 16 artículos) muestran incremento de precisión, robustez o estabilidad.
Metodologías más frecuentes	1. <i>Machine Learning</i> clásico (37%) – RF, SVR, árboles / 2. <i>Deep Learning</i> (31%) – LSTM, CNN, GRU. / 3. <i>Híbridos/Ensemble</i> (25%) – combinaciones ML+DL o ML+Bayesiano. / 4. <i>Econométricos tradicionales</i> (7%) – GARCH/ARIMA.
Contextos más analizados	Crisis sanitarias (31%), económicas/financieras (25%), energéticas (19%), climáticas (19%), políticas (6%).
Tendencia general	Los modelos más robustos son los <i>multivariantes</i> y <i>multimodales</i> , integrando factores contextuales (macro, sociales o ambientales).

Discusión de Resultados

Los hallazgos de esta revisión sistemática confirman que la resiliencia de los modelos predictivos basados en inteligencia artificial no depende exclusivamente de su arquitectura técnica, sino también de su capacidad para adaptarse a los ciclos y rupturas característicos de las crisis económicas. Al comparar los estudios analizados, se

evidencia una tensión constante entre la precisión algorítmica y la sensibilidad contextual del modelo. Mientras que autores como Abdullayev et al. (2024) y Kumar et al. (2022) ponen énfasis en el fortalecimiento técnico mediante metaheurísticas o algoritmos híbridos, investigaciones como las de Korol & Fotiadis (2022) y Bhattacharya et al. (2023) muestran que la resiliencia predictiva se incrementa al integrar variables socioeconómicas y cualitativas, alineándose con la teoría de los ciclos económicos adaptativos. Esto indica que la estabilidad de los modelos no puede analizarse sin considerar los factores estructurales que condicionan la respuesta económica ante un shock.

De manera complementaria, los resultados se vinculan con la teoría de resiliencia regional (Wang & Li, 2022), que sostiene que las economías responden de manera diferenciada según su estructura productiva, capacidad institucional y grado de diversificación. En los modelos revisados, las redes neuronales y los enfoques híbridos demostraron mayor estabilidad en regiones con instituciones financieras robustas, mientras que, en economías más vulnerables, estos modelos tienden a sobreajustarse o subestimar el impacto de la crisis. Esta relación refuerza la idea de que la resiliencia algorítmica tiene una dimensión territorial y estructural, más allá de lo meramente computacional.

Desde una perspectiva comparativa, los estudios sobre la crisis financiera global de 2007–2008 (Gifu, 2025; Yu & Chang, 2020) evidenciaron la pérdida de precisión de los modelos clásicos frente a choques abruptos, mientras que investigaciones recientes sobre la pandemia (Kim et al., 2025; Lezcano et al., 2023; Wu et al., 2022) resaltaron el valor de la multimodalidad y el aprendizaje profundo para mantener la estabilidad predictiva en contextos de alta incertidumbre. No obstante, pocos estudios han explorado la interacción simultánea de crisis múltiples —financieras, sanitarias y climáticas— como planteó Tamasiga (2023), lo que representa una laguna importante para consolidar un marco integrador de resiliencia económica basado en IA.

En el ámbito ético, se detectó una marcada carencia en la discusión sobre sesgos algorítmicos y la opacidad de los modelos utilizados. Ninguno de los trabajos revisados profundiza en los efectos distributivos derivados del uso de sistemas de IA durante crisis, lo que genera riesgos de exclusión, especialmente en economías caracterizadas por una limitada transparencia de datos. Esta omisión contrasta con los principios de la IA responsable, que exigen equidad, explicabilidad y rendición de cuentas en contextos de alta vulnerabilidad social. Incorporar esta dimensión ética resulta imprescindible para asegurar que la resiliencia tecnológica no se consiga a costa de agravar desigualdades económicas.

Respecto a la aplicabilidad, la mayoría de las investigaciones provienen de países industrializados, donde los entornos de datos son más robustos y las instituciones financieras cuentan con mayor estabilidad. Por el contrario, las economías latinoamericanas y emergentes —caracterizadas por alta informalidad y escasa disponibilidad de datos abiertos— enfrentan desafíos adicionales. Para estos contextos, la evidencia aportada por autores como Reis et al. (2022) y Moraglio & Ragusa (2024) sugiere que la incorporación de datos textuales y fuentes no estructuradas podría potenciar la adaptabilidad de los modelos predictivos. Además, integrar variables institucionales, sociales y ambientales propias de América Latina permitiría desarrollar sistemas más realistas y sensibles a la heterogeneidad regional.

Finalmente, el análisis conjunto de los autores revisados muestra que la resiliencia de los modelos de IA debe concebirse como una propiedad emergente que integra precisión técnica, contextualización económica y responsabilidad ética. En consecuencia, avanzar hacia un metamarco interpretativo de resiliencia algorítmica —que integre teorías sobre crisis, resiliencia regional y justicia de datos— constituye una oportunidad fundamental para potenciar futuras investigaciones y orientar la formulación de políticas públicas fundamentadas en evidencia.

Conclusiones

Los hallazgos de esta revisión sistemática evidencian que la resiliencia de los modelos predictivos basados en inteligencia artificial frente a crisis económicas depende principalmente de su capacidad para integrar variables macroeconómicas, estructurales y contextuales, más allá del diseño técnico del algoritmo. Esta relación indica que la eficacia predictiva no reside exclusivamente en el algoritmo, sino en su adecuación al entorno económico, social y político en el que se aplica.

Desde una perspectiva práctica, los resultados brindan orientaciones claras para diversos actores. En el caso de los gobiernos, se recomienda fomentar políticas de gobernanza digital y acceso a datos abiertos que permitan alimentar los modelos de IA con información económica en tiempo real, facilitando respuestas rápidas ante escenarios de crisis. Para el sector bancario, se sugiere invertir en modelos híbridos que fusionen aprendizaje automático con análisis de riesgo macroeconómico, fortaleciendo así la detección temprana de inestabilidades financieras.

Por su parte, las empresas, especialmente en economías emergentes, deberían adoptar modelos adaptativos que incluyan variables exógenas como shocks de precios, restricciones crediticias o eventos geopolíticos, para anticipar posibles interrupciones y garantizar la continuidad operacional.

En el ámbito académico, este estudio contribuye a cerrar un vacío relevante al ofrecer una visión sistemática y comparativa sobre la resiliencia de los modelos predictivos de IA ante diferentes tipos de crisis, un aspecto poco explorado en la literatura actual. Por ello, se plantea como línea futura de investigación el desarrollo de modelos integrados de resiliencia económica basados en IA explicable (XAI), así como el análisis longitudinal del desempeño de dichos modelos en regiones con alta volatilidad económica. De igual modo, resulta pertinente investigar la interacción entre resiliencia tecnológica, estabilidad institucional y sostenibilidad económica, con el fin de consolidar un marco interdisciplinario que fortalezca la toma de decisiones en contextos de incertidumbre global.

Referencias

- Abdullayev, I., Akhmetshin, E., Kosorukova, I., Klochko, E., Cho, W., & Joshi, G. P. (2024). Modeling of extended osprey optimization algorithm with Bayesian neural network: An application on Fintech to predict financial crisis. *AIMS Mathematics*, 9(7), 17555–17577. <https://doi.org/10.3934/math.2024853>
- Addisu Kassie, B., & Bang, J. (2022). Is it recession-proof? Masstige purchase intention: The moderating effect of perceived economic crisis. *SHS Web of Conferences*, 132, 01013. <https://doi.org/10.1051/shsconf/202213201013>
- Amamou, S., Daoud, M., & Bargaoui, S. (2024). Green bonds forecasting: Evidence from pre-crisis, COVID-19 and Russian–Ukrainian crisis frameworks. *Journal of Economic Studies*, 52(1), 179–193. <https://doi.org/10.1108/jes-01-2024-0061>
- Ben Ayed, W., & Ben Hassen, R. (2024). The Basel 2.5 capital regulatory framework and the COVID-19 crisis: evidence from the ethical investment market. *PSU Research Review: An International Journal*, 8(3), 727–748. <https://doi.org/10.1108/PRR-06-2022-0082>
- Bhattacharya, R., Kafila, Somanchi, H. K., Haralayya, B., Nagpal, P., & Chitsimran. (2023). Modified Grey Wolf Optimizer with Sparse Autoencoder for financial crisis prediction in small marginal firms. En *Proceedings of the Second International Conference on Electronics and Renewable Systems (ICEARS-2023)* (pp. 907–913). IEEE. <https://doi.org/10.1109/ICEARS56392.2023.10085618>
- Chumachenko, D., Dudkina, T., Chumachenko, T., & Morita, P. P. (2023). Epidemiological implications of war: Machine learning estimations of the Russian invasion's effect on Italy's COVID-19 dynamics. *Computation*, 11(11), 221. <https://doi.org/10.3390/computation11110221>
- Evgrafova, R., Ivashkovskaya, I., & Шопухова, E. (2023). Corporate resilience in cancel culture times", *Journal of Corporate Finance Research / Корпоративные Финансы*, 17(4), 19–37. <https://doi.org/10.17323/j.jcfr.2073-0438.17.4.2023.19-37>
- Gifu, D. (2025). Exploring the potential of e-learning in economic crisis prediction. *Proceedings of the International Conference on Virtual Learning*, 20, 144–152. https://www.researchgate.net/publication/390562045_Exploring_the_potential_of_e-learning_in_economic_crisis_prediction
- Hamdi, M., & Chkili, W. (2019). An artificial neural network augmented GARCH model for Islamic stock market volatility: Do asymmetry and long memory matter? *Economic Research Forum*, (Working Paper No. 1325). <https://erf.org/publications/an-artificial-neural-network-augmented-garch-model-for-islamic-stock-market-volatility-do-asymmetry-and-long-memory-matter/>
- Iuga, I., & Mihalciuc, A. (2020). Major crises of the XXIst century and impact on economic growth. *Sustainability*, 12(22), 9373. <https://doi.org/10.3390/su12229373>
- Karaev, A. K., & Borisova, O. V. (2025). Prospective models of financial forecasting of budget revenues. *Finance: Theory and Practice*, 29(1), 20–33. <https://doi.org/10.26794/2587-5671-2025-29-1-20-33>
- Kim, T. H., Chinthaginjala, R., Srinivasulu, A. et al. (2025). COVID-19 health data prediction: a critical evaluation of CNN-based approaches. *Scientific Reports*, 15, 9121. <https://doi.org/10.1038/s41598-025-92464-0>
- Kiranmai Balijepalli, N. S. S., & Thangaraj, V. (2025). Prediction of cryptocurrency's price using ensemble machine learning algorithms. *European Journal of Management and Business Economics*. <https://doi.org/10.1108/EJMBE-08-2023-0244>
- Korol, T., & Fotiadis, A. K. (2022). Implementing artificial intelligence in forecasting the risk of personal bankruptcies in Poland and Taiwan. *Oeconomia Copernicana*, 13(2), 407–438. <https://doi.org/10.24136/oc.2022.013>

- Kotan, K., Kotan, B., & Kirişoğlu, S. (2025). Detection of economic crises with language models and comparative analysis of simple time series analysis models and machine learning algorithms on the stock market. *IEEE Access*, 13, 83255–83274. <https://doi.org/10.1109/ACCESS.2025.3567743>
- Kumar, K. P. M., Dhanasekaran, S., Punithavathi, I. S. H., Duraipandy, P., Dutta, A. K. et al. (2022). Bird Swarm Algorithm with Fuzzy Min-Max Neural Network for Financial Crisis Prediction. *Computers, Materials & Continua*, 73(1), 1541–1555. <https://doi.org/10.32604/cmc.2022.028338>
- Kyriakou, N., Loukis, E., & Maragoudakis, M. (2023). Predicting firms' resilience to economic crisis using artificial intelligence for optimizing economic stimulus programs. *Transforming Government: People, Process and Policy*, 18(3), 400–416. <https://doi.org/10.1108/tg-08-2022-0112>
- Lezcano Lastra, A., Llamosas García, G., López Cagigas, A., & Parra Rodríguez, F. J. (2023). Predicting the tide of the pandemic: An in-depth analysis of forecasting models for COVID-19 in Cantabria. *Boletín de Estadística e Investigación Operativa (BEIO)*, 39(2), 36–49. <https://www.seio.es/beio/predicting-the-tide-of-the-pandemic-an-in-depth-analysis-of-forecasting-models-for-covid-19-in-cantabria/>
- Li, D. (2023). Research on forecasting model of corporate financial crisis based on pattern recognition and artificial intelligence. *Applied Mathematics and Nonlinear Sciences*, 8(2), 3553–3566. <https://doi.org/10.2478/amns.2021.2.00268>
- Li, H., Cheng, Z. Y., Fu, X., Liu, M., Liu, P., Cao, W., Liang, Z., Wang, F., & Sun, B. (2024). Decoding acute myocarditis in patients with COVID-19: Early detection through machine learning and hematological indices. *Computers in Biology and Medicine*, 173, 108097. <https://doi.org/10.1016/j.isci.2023.108524>
- Liu, H., & Shen, Y. (2020). Forecasting carbon price using empirical wavelet transform and GRU neural network. *Applied Energy*, 262, 114567. <https://doi.org/10.1080/17583004.2019.1686930>
- Liu, X., Zhi, W., & Akhundzada, A. (2025). Enhancing performance prediction of municipal solid waste generation: A strategic management. *Frontiers in Environmental Science*, 13, 1553121. <https://doi.org/10.3389/fenvs.2025.1553121>
- Manousiadis, C., & Gaki, E. (2023). Prediction models and testing of resilience in regions: Covid19 economic impact in USA counties study case, *REGION*. Vienna, Austria, 10(1), 113–132. <https://doi.org/10.18335/region.v10i1.449>
- Moraglio, F., & Ragusa, C. (2024). Day-Ahead Electricity Price Forecasting in the Contemporary Italian Market. *Energy Economics*, 126, 107278. <https://doi.org/10.1109/ACCESS.2024.3403422>
- Mousavimehr, S. M., & Kavianpour, M. R. (2025). A non-stationary downscaling and gap-filling approach for GRACE/GRACE-FO data under climatic and anthropogenic influences. *Applied Water Science*, 15, 91 (2025). <https://doi.org/10.1007/s13201-025-02427-z>
- Puli, S., Thota, N., & Subrahmanyam, A. (2024). Assessing machine learning techniques for predicting banking crises in India. *Journal of Risk and Financial Management*, 17(4), 141. <https://doi.org/10.3390/jrfm17040141>
- Ramakrishnaiah, Y., Macesic, N., Webb, G., Peleg, A., & Tyagi, S. (2025). EHR-ML: A data-driven framework for predictive modeling under crisis conditions. *International Journal of Medical Informatics*, 196, 105816. <https://doi.org/10.1016/j.ijmedinf.2025.105816>
- Reier Forradellas, R. F., & Garay Gallastegui, L. M. (2021). Digital transformation and artificial intelligence applied to business: Legal regulations, economic impact and perspective. *Laws*, 10(3), 70. <https://doi.org/10.3390/laws10030070>
- Reis, I., Marcondes, R., & Oliveria, S. (2022). On the enrichment of time series with textual data for forecasting agricultural commodity prices. *MethodsX*, 9, 101758. <https://doi.org/10.1016/j.mex.2022.101758>
- Rodrigues, L., Rodrigues, L., & Bacchi M. R. P. (2022). Performance evaluation of forecasting models based on time series and machine learning techniques: an application to light fuel consumption in Brazil. *International Journal of Energy Sector Management*, 16(4), 636–658. <https://doi.org/10.1108/IJESM-02-2021-0009>
- Tamasiga, P., Ouassou, E. H., Onyeaka, H., Bakwena, M., Happonen, A., & Molala, M. (2023). Forecasting disruptions in global food value chains to tackle food insecurity: The role of AI and big data analytics – A bibliometric and scientometric analysis. *Journal of Agriculture and Food Research*, 14, 100819. <https://doi.org/10.1016/j.jafr.2023.100819>
- Wang, X., & Li, M. (2022). Determinants of Regional Economic Resilience to Economic Crisis: Evidence from Chinese Economies. *Sustainability*, 14(2), 809. <https://doi.org/10.3390/su14020809>
- Wu, J. T.-Y., Armengol de la Hoz, M. Á., Kuo, P.-C., Paguio, J. A., Yao, J. S., Dee, E. C., Yeung, W., Jurado, J., Moulick, A., Milazzo, C., Peinado, P., Villares, P., Cubillo, A., Varona, J. F., Lee, H.-C., Estirado, A., Castellano, J. M., & Celi, L. A. (2022). Developing and validating multi-modal models for mortality

- prediction in COVID-19 patients: A multi-center retrospective study. *Journal of Digital Imaging*, 35, 1514–1529. <https://doi.org/10.1007/s10278-022-00674-z>
- Xie, T., Huang, Z., Tan, T., & Chen, Y. (2024). Forecasting China's agricultural carbon emissions: A comparative study based on deep learning models. *Ecological Informatics*, 82, 102661. <https://doi.org/10.1016/j.ecoinf.2024.102661>
- Xu, Z., & Shi, J. (2025). Research on the national security risk assessment model: A case study of political security in China. *Humanities and Social Sciences Communications*, 12(1), 906. <https://doi.org/10.1057/s41599-025-05278-w>
- Yang, D., Tang, Y., Chan, V., Fang, Q., Chan, S., Luo, H., Wong, I., Ou, H., Chan, E., Bishai, D., Chen, Y., Knapp, M., Jit, M., & Craig, D., Li, X. (2025). Population-wide depression incidence forecasting comparing autoregressive integrated moving average and vector autoregressive integrated moving average to temporal fusion transformers: Longitudinal observational study. *Journal of Medical Internet Research*, 27, e67156. <https://doi.org/10.2196/67156>
- Yu, J., & Chang, K.-C. (2020). Neural network predictive modeling on dynamic portfolio management—A simulation-based portfolio optimization approach. *Journal of Risk and Financial Management*, 13(11), 285. <https://doi.org/10.3390/jrfm13110285>

CONTRIBUCIÓN DE LA AUTORÍA:

1. Conceptualización: Jorsi Ericson Joel Balcázar Gallo, Cecilia Maria Madrid Villarreyes
2. Curación de datos: Leandro Adolfo Pérez Cruz, Javier Valdiviezo Miranda
3. Análisis formal: Javier Valdiviezo Miranda
4. Investigación: Jorsi Ericson Joel Balcázar Gallo, Cecilia Maria Madrid Villarreyes
5. Metodología: Jorsi Ericson Joel Balcázar Gallo, Cecilia Maria Madrid Villarreyes, Javier Valdiviezo Miranda
6. Dirección del proyecto: Jorsi Ericson Joel Balcázar Gallo, Leandro Adolfo Pérez Cruz
7. Recursos: Jorsi Ericson Joel Balcázar Gallo, Cecilia Maria Madrid Villarreyes, Leandro Adolfo Pérez Cruz
8. Supervisión: Jorsi Ericson Joel Balcázar Gallo
9. Validación: Javier Valdiviezo Miranda
10. Visualización: Jorsi Ericson Joel Balcázar Gallo, Leandro Adolfo Pérez Cruz
11. Redacción - borrador original: Jorsi Ericson Joel Balcázar Gallo, Cecilia Maria Madrid Villarreyes, Leandro Adolfo Pérez Cruz, Javier Valdiviezo Miranda