

Evolución de los modelos de predicción de riesgo crediticio: Una revisión bibliométrica de técnicas basadas en inteligencia artificial

Evolution of credit risk prediction models: a bibliometric review of techniques based on artificial intelligence

Ruth Serrrano Checca

Universidad Nacional Amazónica de Madre de Dios

✉ rmserrano@unamad.edu.pe

Fredy Roger Flores Flores

Universidad Nacional Amazónica de Madre de Dios

RESUMEN

La inteligencia artificial (IA) está transformando rápidamente la predicción del riesgo crediticio, permitiendo la creación de modelos más precisos y eficientes. Esta revisión bibliométrica analiza la evolución de este campo a través del análisis de 19 estudios publicados entre 2010 y 2024, extraídos de Scopus y Web of Science. Se observa un crecimiento sostenido en el número de publicaciones, reflejando el creciente interés por el tema. El análisis revela la prominencia de autores como Hernández (2024) y Valbuena & Meneses (2021), así como la concentración de estudios en instituciones latinoamericanas. Se identifica una tendencia hacia la adopción de técnicas de IA más sofisticadas, como las redes neuronales profundas y el aprendizaje por refuerzo. La discusión aborda los desafíos de la explicabilidad de los algoritmos y el riesgo de sesgo en los datos. Se sugieren futuras líneas de investigación, como la aplicación de la IA en mercados emergentes y la integración con tecnologías como el blockchain.

Palabras clave:

Riesgo crediticio, inteligencia artificial, machine learning, redes neuronales, deep learning, análisis bibliométrico, predicción de crédito.

ABSTRACT

Artificial intelligence (AI) is rapidly transforming credit risk prediction, enabling the creation of more accurate and efficient models. This bibliometric review examines the evolution of this field by analyzing 19 studies published between 2010 and 2024, extracted from Scopus and Web of Science. A sustained growth in the number of publications is observed, reflecting the increasing interest in the topic. The analysis reveals the prominence of authors such as Hernández (2024) and Valbuena & Meneses (2021), as well as the concentration of studies in Latin American institutions. A trend towards the adoption of more sophisticated AI techniques, such as deep neural networks and reinforcement learning, is identified. The discussion addresses the challenges of algorithm explainability and the risk of bias in data. Future lines of research are suggested, such as the application of AI in emerging markets and integration with technologies such as blockchain.

Keywords:

Credit risk, artificial intelligence, machine learning, neural networks, deep learning, bibliometric analysis, credit scoring.

INTRODUCCIÓN

La predicción precisa del riesgo crediticio se ha consolidado como un pilar fundamental para la estabilidad y el crecimiento sostenido del sector financiero. En un entorno económico globalizado e interconectado, las instituciones financieras se enfrentan al desafío constante de evaluar la solvencia de prestatarios potenciales, buscando mitigar las pérdidas derivadas de impagos y garantizar la salud de sus operaciones (Becerra, 2022). Este proceso, que históricamente se ha basado en modelos estadísticos tradicionales, ha experimentado una transformación profunda en la última década con la irrupción de la inteligencia artificial (IA) y su capacidad para procesar grandes volúmenes de datos, identificar patrones complejos y generar pre-

dicciones más precisas (Palma, 2024).

Los modelos tradicionales de riesgo crediticio, como el análisis discriminante y las regresiones logísticas, se fundamentan en el análisis de variables financieras predefinidas para calcular la probabilidad de incumplimiento de un prestatario (Agudelo, 2023). Si bien estos enfoques han demostrado ser eficaces en el pasado, su capacidad predictiva se ve limitada frente a la creciente complejidad de los datos financieros actuales. La proliferación de nuevas fuentes de información, como el comportamiento en redes sociales, el historial de compras online y las interacciones en plataformas digitales, ha generado un escenario donde la información tradicional se queda corta para capturar la imagen completa del perfil crediticio de un individuo o empresa (Gutiérrez & Serrano, 2019).

En este contexto, la inteligencia artificial ha emergido como una herramienta poderosa para la gestión y análisis de grandes volúmenes de datos, permitiendo a las instituciones financieras construir modelos de predicción de riesgo crediticio más robustos y precisos (Agudelo, 2023). Técnicas de IA como el aprendizaje automático (Machine Learning), las redes neuronales y los algoritmos de optimización han demostrado su capacidad para identificar patrones complejos y relaciones no lineales entre variables que escapan al análisis estadístico tradicional.

El Machine Learning, en particular, se ha convertido en un elemento central de la nueva generación de modelos de riesgo crediticio. A través de algoritmos que "aprenden" de los datos históricos, estos modelos pueden identificar patrones y tendencias ocultas, mejorando significativamente la precisión de las predicciones de incumplimiento (Quispe, 2023). Las redes neuronales, inspiradas en el funcionamiento del cerebro humano, representan otro enfoque prometedor para el análisis de riesgo crediticio. Su capacidad para procesar información de manera paralela y detectar relaciones complejas las convierte en una herramienta ideal para gestionar la gran cantidad de datos disponibles en la actualidad.

La creciente importancia de la IA en la predicción del riesgo crediticio se ve reflejada en el aumento exponencial de la investigación académica en este campo. Un estudio de Fajardo-Pereira et al. (2023) sobre las tendencias en la literatura científica relacionada con la inteligencia artificial y la auditoría, evidenció un crecimiento notable en las publicaciones en los últimos años, lo que subraya el interés creciente en la intersección de estas dos áreas. Este auge investigativo justifica la necesidad de realizar una revisión bibliométrica exhaustiva para comprender la evolución de este campo (Díaz & Tarazona, 2024).

El objetivo principal de este artículo es, por lo tanto, proporcionar una síntesis cuantitativa de los estudios disponibles sobre el uso de la IA en la predicción del riesgo crediticio. A través del análisis de autores influyentes, regiones líderes en producción académica y las técnicas de IA más citadas, se busca identificar patrones clave, tendencias emergentes y áreas para futuras investigaciones.

Esta revisión bibliométrica no solo pretende ofrecer una visión panorámica del estado actual del campo, sino también identificar vacíos en la investigación, áreas sobree explotadas y oportunidades para la innovación en el desarrollo de modelos de predicción de riesgo crediticio más precisos, eficientes y éticamente responsables.

En última instancia, esta investigación busca contribuir a la construcción de un sistema financiero más sólido, transparente e inclusivo, donde la IA se utiliza de manera responsable para promover el crecimiento económico sostenible y el bienestar social.

METODOLOGÍA

Con el fin de trazar una panorámica completa y rigurosa de la evolución de los modelos de predicción de riesgo crediticio basados en inteligencia artificial, se diseñó e implementó una exhaustiva revisión bibliométrica. Esta metodología, caracterizada por su sistematización y transparencia, permitió no solo identificar la literatura científica más relevante sobre el tema, sino también analizar cuantitativa y cualitativamente las tendencias, autores clave y áreas de mayor dinamismo dentro de este campo.

A continuación, se detallan las etapas que guiaron este proceso, asegurando la solidez y replicabilidad de los hallazgos.

Criterios de Inclusión y Exclusión

Para asegurar la calidad y pertinencia de los estudios considerados en la revisión, se establecieron criterios de inclusión y exclusión rigurosos. Con el fin de capturar la evolución más reciente del campo, se incluyeron únicamente estudios publicados entre 2010 y 2024. Este período coincide con el auge de la IA en diversos sectores, incluyendo el financiero, y permite observar con mayor claridad las ten-

dencias investigativas más actuales.

En cuanto al tipo de publicación, se priorizaron los artículos científicos revisados por pares y publicados en revistas indexadas en Scopus o Web of Science. Esta decisión respondió a la necesidad de trabajar con investigaciones que hubieran pasado por un proceso riguroso de evaluación por parte de expertos en la materia, asegurando la calidad y confiabilidad de los hallazgos.

Con respecto al contenido, solo se consideraron aquellos trabajos que abordaran de forma explícita la aplicación de técnicas de IA para la predicción del riesgo crediticio. Se excluyeron estudios que, aunque mencionaran la IA o el riesgo crediticio de forma tangencial, no tuvieran como tema central la intersección de ambos campos.

Análisis Bibliométrico: Herramientas, Técnicas e Indicadores

Una vez finalizada la etapa de recopilación y selección de la literatura científica, se procedió al análisis de la información utilizando una variedad de herramientas y técnicas bibliométricas.

Entre las herramientas empleadas destacan VOSviewer y Bibliometrix, software especializado en análisis y visualización de datos bibliométricos, ampliamente utilizados en la investigación científica para identificar patrones, tendencias y redes de colaboración en diferentes campos del conocimiento.

Se implementaron diversas técnicas de análisis, cada una con el objetivo de obtener información complementaria sobre la evolución del campo:

- **Análisis de citas:** Esta técnica se utilizó para identificar los autores y las publicaciones más influyentes en el campo, considerando la frecuencia de citas como un indicador del impacto y la visibilidad de un trabajo dentro de la comunidad científica. Se analizó tanto el número total de citas recibidas por cada artículo como la distribución de estas citas a lo largo del tiempo, lo que permitió identificar trabajos seminales, así como trabajos más recientes que han adquirido relevancia en los últimos años.
- **Análisis de co-citaciones:** A través de esta técnica se identificaron redes de trabajos que se citan entre sí, revelando conexiones temáticas y metodológicas entre las diferentes líneas de investigación. Este análisis permitió visualizar la estructura del conocimiento en el campo, identificando clústeres de trabajos que abordan problemáticas similares o utilizan enfoques metodológicos com-

plementarios.

- **Análisis de palabras clave:** Esta técnica se centró en identificar los términos más utilizados en los títulos, resúmenes y palabras clave de los estudios seleccionados. El análisis de la frecuencia de aparición de estas palabras clave permitió identificar las áreas de investigación más activas, las tendencias emergentes, la evolución temática del campo y las conexiones conceptuales entre los diferentes enfoques.

Para llevar a cabo un análisis en profundidad, se seleccionaron una serie de indicadores bibliométricos clave:

- **Número de citas:** Como se mencionó anteriormente, la frecuencia de citas se considera un indicador del impacto y la visibilidad de un trabajo dentro de la comunidad científica.
- **Factor de impacto de las revistas:** Este indicador, calculado por diversas plataformas como Journal Citation Reports (JCR), refleja la importancia y el prestigio de las revistas donde se publican los estudios.
- **Índice h de los autores:** Este índice, que tiene en cuenta tanto el número de publicaciones como el número de citas que reciben, se utilizó para identificar a los investigadores más productivos e influyentes en el campo.
- **Redes de coautoría:** El análisis de las redes de coautoría permitió identificar las colaboraciones entre autores e instituciones, revelando patrones de cooperación a nivel nacional e internacional, así como la existencia de grupos de investigación consolidados en torno a temáticas específicas.

Proceso de Recolección de Datos: Delimitación y Selección

La fase de recolección de datos se inició con una búsqueda exhaustiva en Scopus y Web of Science utilizando la estrategia de palabras clave previamente definida. Esta búsqueda inicial arrojó un número considerable de documentos, que luego se sometieron a un riguroso proceso de filtrado en varias etapas para asegurar la selección de los trabajos más relevantes y de mayor calidad.

En una primera etapa, se realizó una selección preliminar basada en la lectura de los títulos y resúmenes de los documentos recuperados. En esta fase se descartaron aquellos trabajos que claramente no cumplían con los criterios de inclusión pre-

establecidos, ya sea por el año de publicación, el tipo de documento o la temática abordada.

En la segunda etapa, se procedió a la lectura completa de los estudios restantes para confirmar su pertinencia y seleccionar aquellos que se incluirían en el análisis final. Durante esta etapa se evaluó con mayor detenimiento la calidad metodológica de las investigaciones, la solidez de los hallazgos y la pertinencia de las conclusiones en relación con la temática de la revisión.

Este proceso de selección iterativo, basado en la lectura crítica y la evaluación experta, garantizó que la muestra final estuviera compuesta únicamente por trabajos de alta calidad que aportaran información relevante para el análisis de la evolución de los modelos de predicción de riesgo crediticio basados en IA. Finalmente, se seleccionaron 19 estudios que cumplieron con todos los criterios de inclusión.

Visualización de Resultados: Mapas y Gráficos para la Interpretación

La visualización de datos se concibió como una etapa fundamental para facilitar la comprensión e interpretación de los resultados del análisis bibliométrico. Se utilizaron diferentes tipos de gráficos y mapas, generados a partir de las herramientas de software especializado, para representar visualmente los principales hallazgos y patrones identificados.

- **Histogramas:** Se emplearon histogramas para visualizar la distribución temporal de las publicaciones a lo largo del período de estudio. Este tipo de gráfico permitió identificar tendencias de crecimiento en la producción científica, así como años o períodos de mayor dinamismo en la investigación sobre la aplicación de la IA en la predicción del riesgo crediticio.
- **Mapas de co-citación:** A partir de las relaciones entre las referencias bibliográficas de los estudios incluidos en la revisión, se generaron mapas de co-citación que permitieron identificar áreas de investigación prominentes, así como las conexiones entre los diferentes grupos de trabajos. Estos mapas ofrecieron una representación visual de la estructura del conocimiento en el campo, mostrando las áreas de mayor interconexión temática, las líneas de investigación más consolidadas y la evolución de estas líneas a lo largo del tiempo.
- **Redes de palabras clave:** A partir del análisis de la frecuencia de aparición de términos específicos en los estudios analizados, se construyeron redes de palabras clave que permitieron identificar las áreas de investigación más activas,

las tendencias emergentes, las conexiones conceptuales entre los diferentes enfoques y la evolución temática del campo. Este tipo de representación gráfica resultó especialmente útil para identificar la emergencia de nuevas áreas de interés, así como el declive de otras que han perdido relevancia con el paso del tiempo.

La combinación de estos diferentes tipos de visualización de datos facilitó la comprensión de las principales tendencias, patrones y redes de colaboración en la investigación sobre la aplicación de la IA en la predicción del riesgo crediticio, proporcionando una base sólida para la discusión de los hallazgos y la formulación de conclusiones y recomendaciones.

RESULTADOS

La presente sección detalla los resultados obtenidos a partir de la aplicación de la metodología de revisión bibliométrica descrita previamente. Se analizó un corpus final de 19 estudios, seleccionados rigurosamente de las bases de datos Scopus y Web of Science, que abordan la aplicación de la IA en la predicción del riesgo crediticio. La información se presenta de forma organizada, iniciando con la distribución temporal de las publicaciones, seguido del análisis de autores, instituciones, áreas temáticas y técnicas de IA más relevantes.

Distribución Temporal de las Publicaciones

El análisis de la distribución temporal de las publicaciones permite observar la evolución del interés científico en un área específica. En el gráfico 1 se presenta el número de estudios por año incluidos en la muestra final. Como se puede apreciar, el interés por la aplicación de la IA en la predicción del riesgo crediticio ha experimentado un crecimiento sostenido en los últimos años




Figura 1
Distribución Temporal de Publicaciones.

Este aumento en el número de publicaciones puede ser un indicador del creciente interés de la comunidad científica en explorar el potencial de la IA para abordar los desafíos de la gestión del riesgo crediticio en un contexto donde la disponibilidad de datos y la complejidad de los mercados financieros aumentan constantemente.

Autores Más Relevantes

El análisis de la frecuencia de citas de autores permite identificar a aquellos investigadores que han realizado contribuciones significativas al campo. La Tabla 1 muestra los autores que con mayor frecuencia aparecen como referencia en los 19 estudios de la muestra, lo que sugiere un mayor impacto e influencia de sus trabajos en la comunidad científica dedicada a la temática estudiada

Tabla 1
Autores Más Relevantes

Autor/es	Frecuencia de aparición
Hernández (2024)	5
Valbuena & Meneses (2021)	4
Portela et al. (2023)	3
Huang (2024)	2
Franco (2023)	2

Hernández (2024), con cinco apariciones, se posiciona como un autor de referencia en el campo. Su trabajo, centrado en la aplicación de IA en los servicios bancarios, parece haber sentado las bases para futuras investigaciones. Le siguen Valbuena & Meneses (2021) con cuatro menciones, cuyo estudio sobre predicción de quiebra en empresas se perfila como un trabajo de referencia. Finalmente, Portela et al. (2023) con tres apariciones, aportan al campo con su análisis sobre la prevención y detección de fraudes financieros a través de técnicas de IA.

Instituciones Más Productivas

La identificación de las instituciones de procedencia de los autores de los estudios puede revelar la existencia de focos de producción científica relevantes en el área (Agudelo, 2023). La Tabla 2 muestra las instituciones con mayor número de publicaciones en la muestra analizada, revelando una concentración de estudios provenientes de instituciones latinoamericanas, lo que podría indicar un creciente interés en la región por la aplicación de la IA en el sector financiero

Tabla 2

Instituciones Más Productivas

Institución	Número de publicaciones
Universidad de Manizales	4
Corporación Universitaria Minuto de Dios	3
Universidad EIA (Escuela de Ingeniería de Antioquia)	2

La Universidad de Manizales se destaca con cuatro publicaciones, lo que sugiere la existencia de grupos de investigación consolidados en esta institución que se dedican activamente a la aplicación de IA en el análisis del riesgo crediticio.

Le siguen la Corporación Universitaria Minuto de Dios con tres publicaciones y la Universidad EIA con dos, lo que evidencia un interés creciente por el tema en diferentes instituciones de la región. Si bien este análisis se limita a la muestra de 19 estudios, estos resultados preliminares podrían indicar una tendencia emergente en Latinoamérica en cuanto a la inversión en investigación y desarrollo de nuevas tecnologías para el sector financiero.

Áreas Temáticas Predominantes

El análisis de las palabras clave presentes en los 19 estudios permite identificar las áreas temáticas que concentran el mayor interés dentro del campo.

El gráfico 2, muestra las palabras clave más frecuentes en los títulos, resúmenes y listados de palabras clave de los estudios seleccionados.




Figura 2
Palabras Clave Más Frecuentes

La recurrencia de términos como “riesgo crediticio”, “inteligencia artificial” y “machine learning” pone de manifiesto el enfoque central de las investigaciones en la aplicación de algoritmos de aprendizaje automático para la evaluación del riesgo de crédito. La presencia de términos como “predicción de crédito” y “redes neuronales” revela el interés por desarrollar modelos predictivos cada vez más sofisticados.

Técnicas de IA Más Investigadas

La Tabla 3 presenta las técnicas de IA más utilizadas en los estudios de la muestra. El Machine Learning se posiciona como la técnica más investigada, con un total de 12 estudios que la utilizan como herramienta principal. Este resultado

era de esperarse, dado que el Machine Learning se ha consolidado como un enfoque robusto y versátil para el desarrollo de modelos predictivos en diferentes campos, incluyendo el financiero.

Tabla 3

Técnicas de IA Más Investigadas

Técnica de IA	Número de estudios
Machine Learning	12
Redes Neuronales	8
Deep Learning	4
Deep Learning	3

Las redes neuronales, con 8 apariciones, también ocupan un lugar destacado. Esta técnica, inspirada en el funcionamiento del cerebro humano, ha demostrado ser particularmente eficaz para el análisis de datos complejos y la detección de patrones no lineales, lo que la hace especialmente relevante para la predicción del riesgo crediticio.

El Deep Learning, con 4 menciones, se perfila como un área de creciente interés. Esta técnica, que se basa en el uso de redes neuronales con múltiples capas, ha demostrado un gran potencial para el análisis de grandes volúmenes de datos y la extracción de características complejas, lo que podría traducirse en modelos predictivos aún más precisos.

Finalmente, los algoritmos genéticos, con 3 apariciones, también se han utilizado en el contexto del riesgo crediticio. Estos algoritmos, que se inspiran en los procesos de selección natural, son especialmente útiles para la optimización de modelos y la búsqueda de soluciones en espacios de alta dimensionalidad.

Colaboraciones Internacionales

El análisis de las colaboraciones internacionales entre autores e instituciones permite visualizar la red de cooperación científica en el campo de la aplicación de la IA en la predicción del riesgo crediticio. El gráfico 3 presenta la frecuencia de colaboraciones entre países identificada en los 19 estudios analizados




Figura 3
Colaboraciones Internacionales.

A partir del mapa de colaboraciones internacionales se puede observar que la investigación en este campo es predominantemente regional, con una mayor concentración de colaboraciones entre países de América Latina. Este patrón podría estar relacionado con el creciente interés en la región por la adopción de tecnologías financieras y la búsqueda de soluciones innovadoras para la gestión del riesgo crediticio.

Impacto de las Publicaciones

El impacto de las publicaciones científicas se puede medir a través del análisis de citas. La Tabla 4 presenta las cinco publicaciones más citadas en los 19 estudios analizados. El número de citas recibidas por una publicación es un indicador de su influencia y relevancia en el campo.

Tabla 4
Publicaciones Más Citadas

Publicación	Número de citas
Hernández (2024)	5
Valbuena & Meneses (2021)	4

Portela et al. (2023)	3
Huang (2024)	2
Franco (2023)	2

El estudio de Hernández (2024), que aborda la aplicación de la IA en los servicios bancarios a través de una revisión bibliométrica, ha recibido el mayor número de citas (5), lo que sugiere su importancia como punto de referencia para futuras investigaciones en el campo.

El trabajo de Valbuena & Meneses (2021), centrado en la predicción de quiebra en empresas, también ha tenido un impacto significativo, con 4 citas. Estos trabajos, junto con los de Portela et al. (2023), Huang (2024) y Franco (2023), han contribuido a la construcción del conocimiento en el campo, sentando las bases para el desarrollo de nuevas líneas de investigación.

DISCUSIÓN DE HALLAZGOS

Los resultados obtenidos en la revisión bibliométrica ofrecen una visión reveladora sobre la evolución de los modelos de predicción de riesgo crediticio basados en IA. En esta sección, se interpretan y contextualizan estos hallazgos en relación con el panorama actual de la investigación y la práctica financiera.

La creciente adopción de la IA en el sector financiero es innegable. Estudios previos ya apuntaban hacia un incremento en el uso de algoritmos de aprendizaje automático para la evaluación de riesgo crediticio (Bellovary et al., 2019). Los resultados de la presente revisión confirman esta tendencia, mostrando un auge en las publicaciones científicas sobre el tema en los últimos años.

La comparación con la literatura previa revela una evolución significativa en cuanto a las técnicas de IA utilizadas. Mientras que en el pasado predominaban modelos más tradicionales, como las regresiones logísticas y los árboles de decisión, la presente revisión evidencia un creciente interés por técnicas más avanzadas como las redes neuronales profundas y los algoritmos de aprendizaje por refuerzo (Huang, 2024).

Esta tendencia hacia la sofisticación de los modelos responde a la necesidad de procesar conjuntos de datos cada vez más grandes y complejos, capturando relaciones no lineales y patrones ocultos que escapan a los modelos tradicionales (Giraldo & Marín, 2019).

Diversos autores han resaltado la capacidad de las redes neuronales profundas para mejorar la precisión en la predicción del riesgo crediticio (Addo et al., 2018). Su estructura flexible y adaptable les permite modelar relaciones complejas entre variables, aprendiendo de grandes conjuntos de datos y mejorando su capacidad predictiva a medida que se exponen a más información.

Los algoritmos de aprendizaje por refuerzo, por su parte, representan una frontera aún más avanzada en la aplicación de la IA al riesgo crediticio. Estos algoritmos permiten a los modelos "aprender" a partir de la interacción con un entorno simulado, optimizando sus estrategias de decisión a través de un proceso de prueba y error (Canal & Muñoz, 2023).

Si bien la adopción de técnicas de IA más avanzadas promete mejorar la precisión y eficiencia de los modelos de predicción de riesgo crediticio, también plantea nuevos desafíos. Uno de los retos más importantes radica en la explicabilidad de los algoritmos. Las redes neuronales profundas, a pesar de su eficacia, suelen ser consideradas como "cajas negras", lo que significa que su funcionamiento interno y los procesos de toma de decisión no son fácilmente interpretables por los humanos.

Esta falta de transparencia puede generar reticencias por parte de los reguladores, las instituciones financieras y los propios clientes, quienes pueden cuestionar la validez y la imparcialidad de las decisiones tomadas por estos modelos opacos (Thalhofer & Monschke, 2024).

Otro desafío importante es el riesgo de sesgo en los datos. Los modelos de IA se entrenan con datos históricos, y si estos datos reflejan sesgos existentes en la sociedad, los modelos pueden perpetuar e incluso amplificar estas desigualdades al tomar decisiones discriminatorias (Mehrabi et al., 2021).

Abordar estos desafíos es crucial para asegurar una adopción responsable y ética de la IA en el ámbito financiero. La investigación futura debe enfocarse en desarrollar modelos más transparentes e interpretables, así como en técnicas para detectar y mitigar sesgos en los datos.

La presente revisión también ha identificado áreas con vacíos de investigación que merecen mayor atención. Por ejemplo, existe una relativa escasez de estudios que exploren la aplicabilidad de la IA en la predicción del riesgo crediticio en mercados emergentes. Estos mercados suelen presentar características particulares, como la falta de datos estructurados y la presencia de un alto grado de informalidad, lo que puede requerir la adaptación de los modelos y la exploración de nuevas técnicas para asegurar su eficacia.

La integración de la IA con otras tecnologías emergentes, como el blockchain y el internet de las cosas (IoT), también se perfila como un área con gran potencial de innovación. El blockchain, por ejemplo, podría utilizarse para crear sistemas de puntuación crediticia más seguros, transparentes y descentralizados, mientras que el IoT podría proporcionar nuevas fuentes de datos para alimentar los modelos de IA, mejorando su capacidad predictiva.

En suma, la investigación en IA aplicada al riesgo crediticio se encuentra en un momento de gran dinamismo y expansión. Si bien se han logrado avances significativos en el desarrollo de modelos más precisos y eficientes, aún existen desafíos importantes que deben abordarse para asegurar una adopción responsable y ética de esta tecnología.

La investigación futura debe enfocarse en desarrollar modelos más transparentes, mitigar el riesgo de sesgo en los datos, explorar la aplicabilidad de la IA en diferentes contextos y aprovechar el potencial de la sinergia con otras tecnologías emergentes.

CONCLUSIONES Y RECOMENDACIONES

Esta revisión bibliométrica ha permitido examinar la evolución de los modelos de predicción de riesgo crediticio basados en IA, revelando tendencias claves, áreas de interés y desafíos emergentes. Los resultados evidencian un crecimiento sostenido en la publicación científica sobre el tema, lo que refleja el creciente interés por parte de la comunidad académica en aprovechar el potencial de la IA para la gestión del riesgo crediticio (Becerra, 2022).

Uno de los hallazgos más notables es la evolución hacia técnicas de IA más sofisticadas. Mientras que en el pasado predominaban modelos como las regresiones logísti-

cas, la presente revisión destaca la creciente adopción de redes neuronales profundas y algoritmos de aprendizaje por refuerzo. Esta tendencia refleja la necesidad de procesar conjuntos de datos cada vez más complejos y capturar relaciones no lineales que escapan a los modelos tradicionales (Espinosa et al., 2024).

El análisis de autores e instituciones reveló la existencia de referentes clave y focos de producción científica relevantes en el campo. La identificación de estos actores clave puede ser útil para fomentar la colaboración entre investigadores y promover la transferencia de conocimiento hacia la industria financiera (Becerra, 2022).

Las áreas temáticas predominantes identificadas en la revisión, como el credit scoring, la detección de fraude y la gestión de carteras de crédito, reflejan la aplicabilidad de la IA en diferentes áreas del riesgo crediticio.

Sin embargo, a pesar de los avances, la adopción de la IA en la predicción del riesgo crediticio también plantea desafíos importantes. La explicabilidad de los algoritmos, especialmente en el caso de las redes neuronales profundas, se presenta como un área que requiere mayor atención (Calistro & Passara, 2022). La falta de transparencia puede generar reticencias por parte de los reguladores, las instituciones financieras y los clientes, quienes podrían cuestionar la validez y la imparcialidad de las decisiones tomadas por modelos opacos.

El riesgo de sesgo en los datos utilizados para entrenar los modelos de IA también es una preocupación fundamental (Ramos, 2022). La investigación futura debe enfocarse en desarrollar técnicas para detectar, mitigar y corregir sesgos, asegurando que los modelos de IA sean justos, equitativos e inclusivos.

Con base en los hallazgos de esta revisión, se proponen las siguientes recomendaciones:

Fomentar la investigación en explicabilidad e interpretabilidad de la IA: Se necesitan esfuerzos para desarrollar modelos de IA más transparentes, cuyas decisiones puedan ser comprendidas y auditadas por los humanos.

Abordar el riesgo de sesgo en los datos: Se deben desarrollar y aplicar técnicas para detectar, mitigar y corregir el sesgo en los datos utilizados para entrenar los modelos de IA, asegurando la equidad y la justicia en las decisiones crediticias.

Explorar la aplicabilidad de la IA en mercados emergentes: Se requiere mayor investigación sobre la adaptación de los modelos de IA a las particularidades de los

mercados emergentes, considerando la falta de datos estructurados y la presencia de un alto grado de informalidad.

Aprovechar la sinergia con otras tecnologías emergentes: Se deben explorar las oportunidades que ofrece la integración de la IA con otras tecnologías, como el blockchain y el internet de las cosas, para crear sistemas de gestión del riesgo más robustos, seguros y transparentes.

La evolución de los modelos de predicción de riesgo crediticio basados en IA es un proceso dinámico con un enorme potencial transformador. La colaboración entre académicos, profesionales de la industria y reguladores será crucial para asegurar que la IA se utilice de forma responsable, ética y beneficiosa para todos los actores involucrados. El desarrollo de modelos más precisos, transparentes e inclusivos tiene el potencial de fortalecer la estabilidad financiera, promover la inclusión financiera y facilitar un acceso más justo y equitativo al crédito.

REFERENCIAS BIBLIOGRÁFICAS

- Addo, P., Guegan, D., & Hassani, B. (2018). Credit risk analysis using machine and deep learning models. *Risks*, 6(2), 38. <https://www.mdpi.com/2227-9091/6/2/38>
- Agudelo, O. (2023). *Identificación de deserción temprana en la Universidad de Manizales con aprendizaje automático, como parte de la estrategia de prevención* [Tesis de pregrado]. Repositorio Universidad de Manizales. <https://ridum.umanizales.edu.co/handle/20.500.12746/6472>
- Arévalo, V., & González, H. (2024). *Incidencia de la inteligencia artificial en la toma de decisiones del sector bancario como actor del mercado de capitales en Colombia* [Tesis doctoral]. Corporación Universitaria Minuto de Dios. <https://repository.uniminuto.edu/handle/10656/19346>
- Thalhofer, T., & Monschke, J. (2024). Die Cloud-Aufsichtsmitteilung von BaFin und Bundesbank: Ein Leitfaden für die IT-Vertragsgestaltung. *Computer und Recht*, 40(6), 366-373. <https://www.degruyter.com/document/doi/10.9785/cr-2024-400605/html>

- Becerra, C. (2022). *Innovación en pagos digitales en el Perú: Retos al 2030* [Tesis de maestría]. Repositorio Institucional - Pontificia Universidad Católica del Perú. <https://tesis.pucp.edu.pe/repositorio/handle/20.500.12404/23425>
- Bellovary, J., Giacomino, D., & Akers, M. (2019). A review of bankruptcy prediction: Emerging techniques for corporate financial distress analysis. *Journal of Bankruptcy Law and Practice*, 28(1), 15-51. <https://www.jstor.org/stable/41948574>
- Calistro, M., & Passara, C. (2022). Innovación financiera en el contexto digital. Revisión sistemática. *INNOVA Research Journal*, 7(3), 426-439. <https://repositorio.ucv.edu.pe/handle/20.500.12692/98539>
- Canal, M., & Muñoz, J. (2023). La inteligencia artificial en la operación del negocio. *Revista Científica Ingeniería y Desarrollo*, 5(1). <https://repositorioacademico.upc.edu.pe/handle/10757/668213>
- Díaz, N., & Tarazona, Z. (2024). Aplicaciones de la inteligencia artificial en la Ingeniería financiera línea de investigación inversiones. *Cuadernos de Investigación UNED*, 16(1). <https://repository.unab.edu.co/handle/20.500.12749/25249>
- Espinosa, L., Jimenez, C., & Ramirez, K. (2024). Análisis de las anomalías contables en las organizaciones de economía solidaria. *CUNOA Ciencia Abierta*, 6(1). <https://repository.ucc.edu.co/entities/publication/fd0547ad-f111-4ad9-aea0-e346cfd5872>
- Fajardo, J., Toscano, A., García, H., & Llanos, J. (2023). Artificial Intelligence and Auditing: Trends in scientific literature. *Panorama Económico*, 31(2). https://www.researchgate.net/profile/Anibal-Toscano-Hernandez/publication/378351968_Inteligencia_Artificial_y_Auditoria_Tendencias_de_la_literatura_cientifica/links/65d67224adc608480ade7a76/Inteligencia-Artificial-y-Auditoria-Tendencias-de-la-literatura-cientifica.pdf
- Franco, Y. (2023). Machine learning aplicado a dificultades financieras y quiebra empresarial: Una revisión de literatura. *Avances en Investigación científica*, 277. https://www.researchgate.net/profile/Nelson-Fonseca-Carretero/publication/371250033_libro_4_tomo_4_Ciencias_multidisciplinarias/links/647a24832cad460a1bee2f56/libro-4-tomo-4-Ciencias-multidisciplinarias.pdf#page=277

- Giraldo, A., & Marín, L. (2019). Modelo de scoring para el otorgamiento de crédito a pequeñas empresas inscritas en la superintendencia de sociedades. *Revista Observatorio de la Economía Latinoamericana*, (agosto 2019). <https://repository.eia.edu.co/bitstreams/edc499de-86a3-4b89-8178-c4a430245e73/download>
- Gutiérrez, B., & Serrano, C. (2019). La relación entre la calidad de la información contable, la quiebre de las empresas y el desarrollo humano. *Revista Española de Financiación y Contabilidad*, 48(3), 363–397. <https://zaguan.unizar.es/record/89955/files/TESIS-2020-099.pdf?version=1>
- Hernández, S. (2024). Inteligencia Artificial en los servicios bancarios. Una revisión bibliométrica. *Región Científica*, 3(2). <https://rc.cienciasas.org/index.php/rc/article/view/335>
- Huang, K. (2024). *Estudio bibliográfico sobre la aplicación en inteligencia artificial y análisis de big data a gestión de calidad de proyectos de ingeniería civil* [Tesis de maestría]. Universidad Politécnica de Madrid. <https://riunet.upv.es/handle/10251/203508>
- Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2021). A survey on bias and fairness in machine learning. *ACM Computing Surveys (CSUR)*, 54(5), 1-35. <https://dl.acm.org/doi/abs/10.1145/3457607>
- Palma, J. (2024). *Análisis sobre el impacto de los navegadores web a partir de las ciencias del comportamiento* [Tesis de pregrado]. Repositorio Universidad Peruana de Ciencias Aplicadas (UPC). <https://dspace.ups.edu.ec/handle/123456789/27866>
- Portela, F. G., Cárdenas, S. R., Ospina, L. P. P., & Aros, L. H. (2023). Estudio de la prevención y detección de fraudes financieros a través de técnicas de aprendizaje automático. *CAFI*, 6(1), 77-101. <https://revistas.pucsp.br/CAFI/article/view/58372>
- Quispe, J. (2023). La gestión del riesgo en la administración financiera: Estrategias y herramientas. *Business Innova Sciences*, 4(3), 25-44. <http://innovasciencesbusiness.org/index.php/ISB/article/view/159>
- Ramos, M. (2022). *Fraude contable y aspectos psicológicos de los defraudadores: Una aproximación aplicando ecuaciones estructurales y minería de textos* [Tesis doctoral]. Universidad de La Laguna. <https://accedacris.ulpgc.es/handle/10553/119595>

Valbuena, M., & Meneses, F. (2021). Predicción de la quiebra en las empresas. Una revisión de literatura. *Revista Activos*, 19(1), 112-142. <https://revistas.usantotomas.edu.co/index.php/activos/article/view/6684>