



De la estadística clásica al machine learning: revisión sistemática sobre el uso de modelos de IA para la gestión del riesgo crediticio

From Classical Statistics to Machine Learning: A Systematic Review on the Use of AI Models for Credit Risk Management

Brayan Estiven Arevalo Vasquez

Barevalo73@unisalle.edu.co

<https://orcid.org/0009-0000-6643-6761>

Maestría en Inteligencia Artificial, Bogotá - Colombia
Universidad de La Salle

Karla Yohana Sánchez Mojica

kasanchez@unisalle.edu.co

<https://orcid.org/0000-0003-3164-4725>

Maestría en Inteligencia Artificial, Bogotá - Colombia
Universidad de La Salle

Resumen

Este artículo es una revisión sistemática de la literatura sobre la aplicación de la inteligencia artificial (IA) en el sector financiero, con énfasis en la evaluación del riesgo crediticio. Para ello, se recopilan y analizan 51 trabajos de investigación publicados en bases de datos académicas internacionales, seleccionados según criterios de relevancia, accesibilidad y calidad de citación. El estudio aborda tanto los métodos tradicionales de análisis crediticio, basados en modelos estadísticos y reglas determinísticas, como los enfoques modernos de aprendizaje automático (ML), que incorporan técnicas computacionales avanzadas para mejorar la predicción y clasificación del riesgo. También se incluye investigación complementaria sobre marcos regulatorios, implicaciones éticas, el impacto ambiental de la IA y su relación con la transformación digital del sector financiero en el contexto de la Industria 4.0.

Los resultados muestran que los modelos de ML tienden a superar a los métodos tradicionales en términos de precisión y capacidad predictiva, aunque la implementación de algunos de ellos enfrenta limitaciones asociadas con la explicabilidad, la transparencia algorítmica y el cumplimiento normativo. La integración efectiva de la IA en la evaluación del riesgo crediticio también requiere un equilibrio entre la innovación tecnológica y la regulación responsable, lo que podría favorecer la adopción de modelos híbridos que combinen la solidez analítica de los métodos tradicionales con la eficiencia predictiva de los modelos de ML.



Palabras clave: Inteligencia artificial, Riesgo crediticio, Aprendizaje automático, Modelos predictivos, Regulación financiera.

Abstract

This article is a systematic review of the literature on the application of artificial intelligence (AI) in the financial sector, focusing on credit risk assessment. To this end, 51 research papers published in international academic databases are compiled and reviewed, selected according to criteria of relevance, accessibility, and citation quality. The study addresses both traditional credit analysis methods, based on statistical models and deterministic rules, and modern machine learning (ML) approaches, which incorporate advanced computational techniques to improve risk prediction and classification. Complementary research on regulatory frameworks, ethical implications, the environmental impact of AI, and its relationship to the digital transformation of the financial sector in the context of Industry 4.0 is also included. The results show that ML models tend to outperform traditional methods in terms of accuracy and predictive capacity, although the implementation of some of them faces limitations associated with explainability, algorithmic transparency, and regulatory compliance. The effective integration of AI into credit risk assessment also requires a balance between technological innovation and responsible regulation, which could favor the adoption of hybrid models that combine the analytical robustness of traditional methods with the predictive efficiency of ML models.

Keywords: Artificial intelligence, Credit risk, Machine learning, Predictive models, Financial regulation.

1. Introducción

En la actualidad el sector bancario ha experimentado una transformación significativa, impulsada por el uso de tecnologías emergentes y la digitalización, las cuales contribuyen en el mejoramiento y automatización de los procesos (Pozzo et al., 2024). Sin embargo, existen factores que representan un gran desafío, como lo es la evaluación del riesgo crediticio, lo cual es un procedimiento fundamental para la toma de decisiones en los procesos de créditos (Sadok et al., 2022). Para el análisis del riesgo crediticio Algunos bancos y entidades usan métodos tradicionales basados en modelos estáticos y datos históricos limitados como registros de pago y puntajes crediticios (Polireddi, 2024). Estos métodos pueden presentar deficiencias en un entorno financiero muy dinámico como el de la actualidad. Donde la toma de decisiones rápidas y precisas, la aparición de nuevos orígenes de datos y la inclusión de poblaciones no bancarizadas demandan soluciones innovadoras (Fatima & Chakraborty, 2024).

La IA es el foco a partir del cual mejorar el rendimiento de otras tecnologías, y es uno de los principales ejes de la evolución de la industria 4.0 (Hajipour et al., 2023). La IA se ha posicionado como una tecnología clave en la década de 2010 y se ha establecido como una tecnología dominante en la década de 2020 (Cruz Salazar et al., 2024). El sector financiero fue de los primeros en adoptar la nueva tecnología: se esperaba que la inteligencia artificial permitiera que las PyMEs fueran competidoras de las grandes organizaciones; no obstante, esto no se materializó en el sector financiero (Cubric & Li, 2024). La industria 4.0 se relaciona estrechamente con la transformación digital, donde los Sistemas Ciber Físicos son el foco y los datos se convierten en un activo esencial para la fabricación inteligente y el avance tecnológico (Trzaska & Sus, 2023).

Por otra parte, también es necesario tener en cuenta los desafíos éticos, regulatorios y desventajas en el uso de la IA, ya que introduce nuevas dimensiones de desigualdad y la necesidad urgente de



marcos regulatorios claros (Beckmann & Hark, 2024). Así como también la explicabilidad de los modelos es crucial para la responsabilidad, transparencia y auditabilidad (Belli & Zingales, 2022). En la regulaciones se debe tener en cuenta el impacto ambiental, ya que se genera un uso intensivo de energía para el entrenamiento y operación de modelos de IA, lo que plantea un desafío significativo para los objetivos de sostenibilidad y el medio ambiente (Tao, 2024). Se debe velar para que los algoritmos inteligentes optimicen los sistemas de almacenamiento de energía y gestionen correctamente la integración de fuentes renovables (Alzoubi & Mishra, 2024).

La disponibilidad de recursos informáticos robustos y grandes volúmenes de datos abren la puerta al uso de algoritmos de evaluación de riesgo crediticio impulsados por IA, como lo son el machine learning y deep learning (Fathy, 2024). El desarrollo y difusión de estas tecnologías se debe en gran medida a la expansión de la capacidad de cómputo, la disponibilidad de grandes cantidades de información, las cualidades y capacidades de los algoritmos especialmente las Redes Neuronales y los métodos de conjunto como Gradient Boosting Machines (Bhuiyan & Sweet, 2025). Los cuales ofrecen ventajas significativas sobre los métodos estadísticos tradicionales (como el análisis discriminante o la regresión logística) (Tóth & Blut, 2024). Estas ventajas se centran en la capacidad de los métodos de IA para manejar la complejidad de los datos modernos y la precisión predictiva (Malik et al., 2024). Los modelos tradicionales como la regresión logística se basan históricamente en heurísticas simplificadas y modelos lineales, lo cual limita el análisis de datos no lineales. En contraste los modelos de IA son capaces de modelar patrones complejos y no lineales (Faheem, 2021).

El presente artículo presenta una revisión sistemática de la literatura sobre la adopción de la IA en el sector financiero para el análisis del riesgo crediticio. El objetivo es analizar las principales tecnologías que se usan para este proceso, y comparar los métodos tradicionales estadísticos con los métodos de IA. Proporcionando argumentos y conexiones entre investigaciones presentes y pasadas. El artículo tiene la siguiente estructura: En la Metodología y datos se describe el proceso de búsqueda de investigaciones relacionadas. En el enfoque informático se analizan los algoritmos y métodos. Para la sección de aplicación de técnicas de ML se profundiza sobre los modelos. En la sección de Resultados y discusión se destacan los principales resultados, finalmente en la conclusión se describen posibles retos.

1. Metodología y datos

Para la búsqueda y selección de las investigaciones relacionadas se usó la metodología Prisma para garantizar la transparencia metodológica, la replicabilidad y la vigilancia académica. PRISMA ofrece un procedimiento estructurado para llevar a cabo revisiones basadas en la evidencia y además añade una lista de control estandarizada y un diagrama de flujo que acompañan que sirve de guía a través de las etapas de identificación, selección, elegibilidad e inclusión. A continuación, se describe el flujo de la metodología:

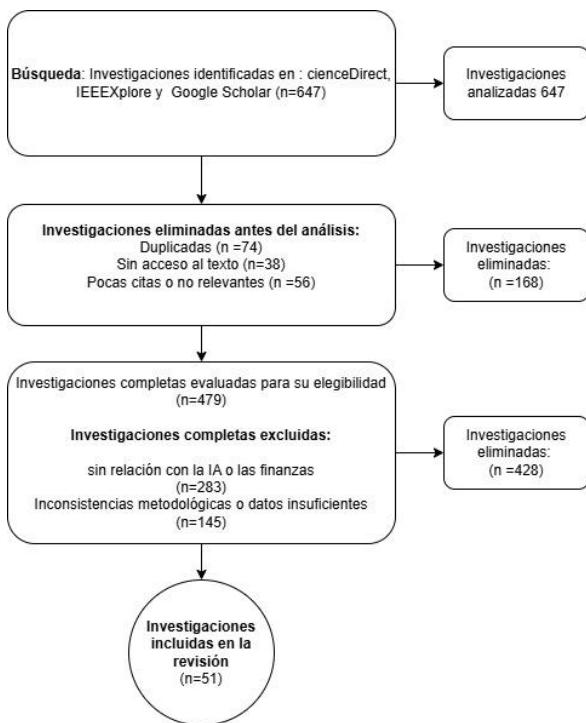


Figura 1 : Flujo de metodología prisma aplicado para este estudio

Se definieron las siguientes plataformas: ScienceDirect, IEEEXplore y Google Scholar. Y se tuvieron en cuenta los siguientes factores:

- **Proceso de selección de palabras clave:** Para la búsqueda se usaron las palabras AI in banking & Credit risk.
- **Criterios de inclusión:** Artículos publicados en los últimos 4 años (2021–2025), publicaciones indexadas en bases de datos de tipo científico (ScienceDirect, IEEEXplore y Google Scholar), investigaciones que giren específicamente sobre el análisis de riesgo crediticio y estudios que hablen sobre el uso de IA o ML en el sector financiero.
- **Criterios de exclusión:** Publicaciones sin revisión por pares o sin acceso al texto completo y estudios que sin citas. En la figura 1 se muestra el flujo de trabajo para la selección de los estudios.

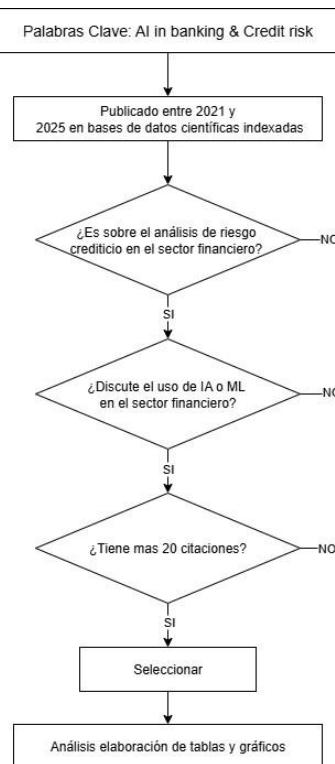


Figura 2 : Flujo para la selección de los artículos

- **Categorías de análisis:** Se definieron las siguientes categorías de análisis: Adopción de la IA en las industrias, modelos de ML para el análisis de información financiera y Modelos de IA para la evaluación de Riesgo Crediticio.

Posterior a la selección de los estudios, se realizaron los siguientes análisis gráficos:

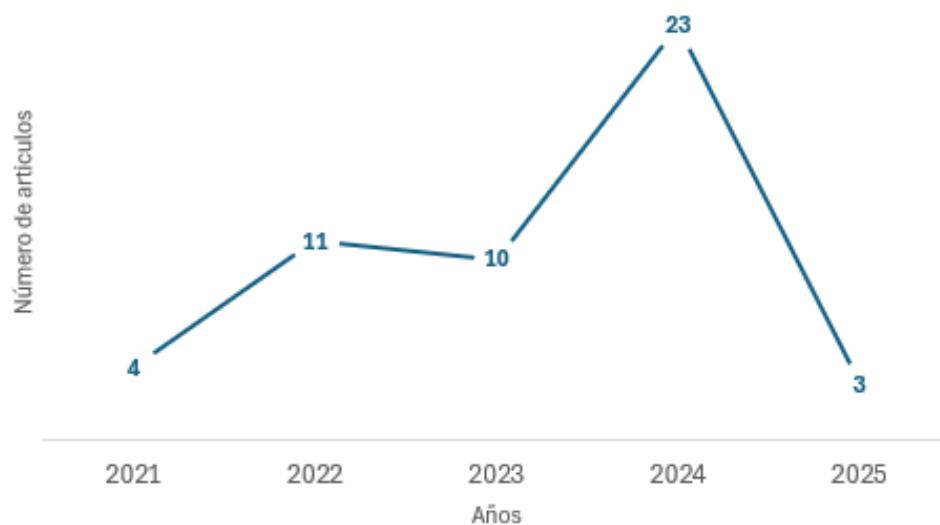


Figura 3 : Cantidad de artículos por año

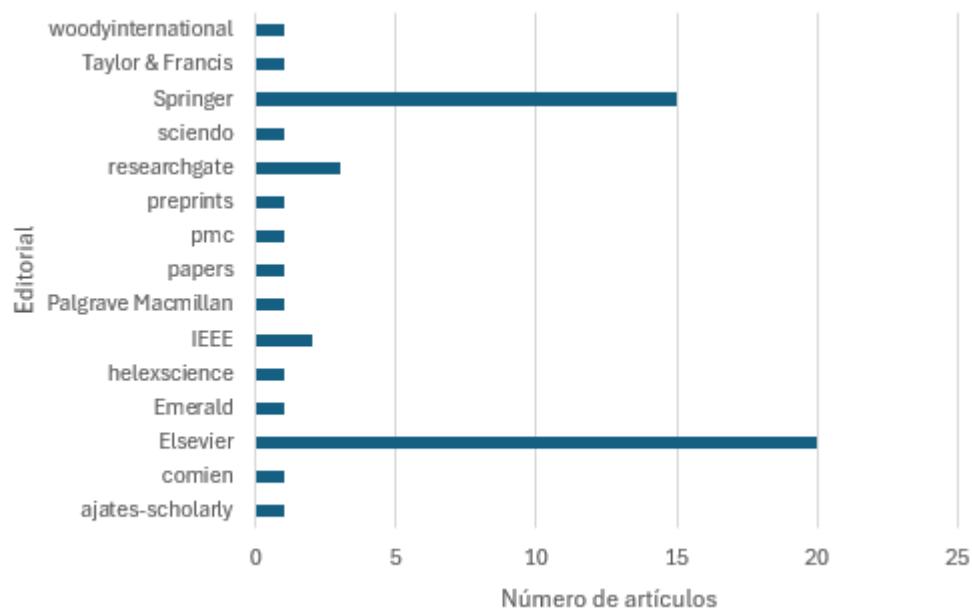


Figura 4: Cantidad de artículos por editorial

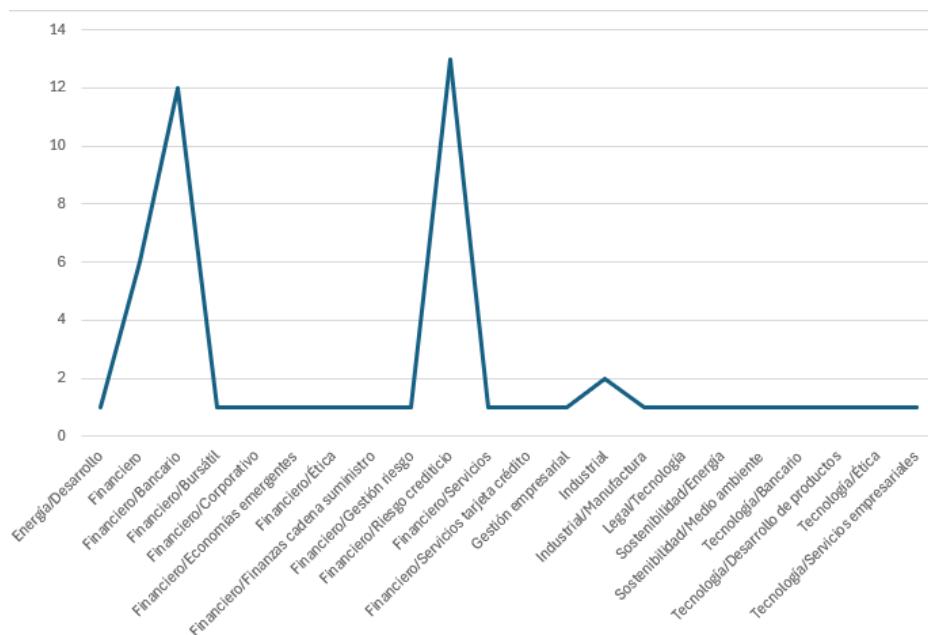


Figura 5: Sectores de aplicación de los estudios

2. Enfoque computacional

El análisis del riesgo crediticio en el sector financiero ha sufrido una fuerte transformación en los últimos 30 años, pasando de evaluaciones basadas en heurísticas manuales a la utilización de sistemas de cómputo complejos. Aun así, la manera de medir el riesgo crediticio se basó en Métodos Tradicionales o Estadísticos, que establecieron las bases para la clasificación de las categorías de comportamiento crediticio de clientes y de las empresas (Kiran et al., 2023), y que se están alineados con las técnicas tradicionales de aprendizaje supervisado (Lappas & Yannacopoulos, 2021), y



modelos relevantes como el Análisis Discriminante y la Regresión Logística (Berrada et al., 2022). A pesar de que estos modelos estadísticos sean el eje central desde hace décadas de la evaluación y clasificación del riesgo crediticio, la llegada de la era de la ciencia de datos y de la Inteligencia Artificial, ha transformado profundamente las finanzas y, por tanto, se necesita una gran capacidad para poder analizar datos y refinar la evaluación del riesgo crediticio y los mecanismos de calificación con mayor precisión y equidad (Fathy, 2024).

Actualmente, el enfoque que se da a la parte informática se ve centrado en la utilización de técnicas complejas, como métodos de Machine Learning (ML) y Deep Learning (DL), que buscan generar soluciones inteligentes a problemas complejos (Bahoo et al., 2024). Se destaca el ML como una de las más importantes subcategorías de la IA, donde se emplean algoritmos para analizar datos entrantes aprender de la experiencia y tomar decisiones. Mostrando una notable mejora y algo más versátil y superior frente a modelos con bases estadísticos tradicionales (Pattnaik et al., 2024). En el ML existen los métodos de aprendizaje supervisado para la clasificación del riesgo, se encuentran algoritmos de uso muy extendido como las máquinas de soporte vectorial (SVM), Bosques aleatorios (RF), o Arboles de decisión (DT), y los modelos de aprendizaje no supervisado como K-Means clustering para segmentar a los clientes y determinar similitudes entre prestatarios, este modelo es básico en la gestión de carteras de crédito (Lappas & Yannacopoulos, 2021). Por otra parte, el Deep Learning (DL) también se consideraría como algo más sofisticado del ML mediante la utilización de Redes Neuronales Artificiales (ANNs) de múltiples capas, una técnica inspirada en el funcionamiento del cerebro humano (Rizal, 2024).

Las metodologías empleadas para el análisis de riesgo crediticio se categorizan de acuerdo con su complejidad y capacidad de análisis de datos. De acuerdo con esto los métodos se segmentan en dos categorías: la primera categoría son los métodos tradicionales que son el pilar histórico para la evaluación de riesgo crediticio. Estos modelos se basan en matemáticas y estadística predefinida y lineal para estimar la probabilidad de incumplimiento (Kiran et al., 2023). Por otro lado la segunda categoría, los modelos de ML para el autor (Kowsar, 2022) han emergido como una alternativa poderosa a los métodos tradicionales. Los modelos de ML son capaces de extraer patrones y relaciones complejos directamente a partir de grandes conjuntos de datos históricos, muchas veces mejores que los modelos tradicionales desde la perspectiva de la precisión predictiva (Rodrigues et al., 2022). A continuación, se profundiza sobre cada categoría:

2.1. métodos tradicionales: Su principal ventaja es la simplicidad e interpretabilidad. Lo que facilita su comprensión, sin embargo, tienen limitaciones complejas para el tratamiento de grandes volúmenes de información (Armagan, 2023). Ya que no pueden capturar relaciones complejas entre variables y patrones no lineales (Singh et al., 2022). Algunos de los métodos más usados son:

- A. Regresión logística: Es el modelo tradicional que se ha usado con más frecuencia en economías en desarrollo por su robustez y escalabilidad. Se modela la probabilidad de que ocurra un resultado binario (como puede ser el caso del 'incumplimiento'), sin requerir estrictas suposiciones de normalidad o igualdad de las varianzas (Faheem, 2021). Para la comparación de modelos de más sofisticación se le usa como modelo de referencia (baseline) en su rendimiento. Así, el Banco Central de Bangladés, etc., recomienda explícitamente el uso de modelos basados en regresiones logísticas o lineales para sus informes regulatorios (Noriega et al., 2023).

- B. Análisis discriminante multivariado: Este método trata de encontrar una combinación de variables financieras que permita clasificar a empresas o personas en las categorías de cumplimiento o incumplimiento. Históricamente, el modelo Z-score de Altman pudo ser el primer modelo que utilizaba MDA para prever la bancarrota (Mi Alnaser et al., 2023). Este modelo fue el predominante en los inicios de la investigación sobre el impago de crédito, aunque se encuentra limitado por la suposición de que existe igualdad de matrices de varianza-covarianza entre grupos y sobre todo es sensible a los outliers (extremos) de la muestra, ya que estos afectan tanto a la media como a la varianza (Faheem, 2021).
- C. Modelos estructurales: Enfoque teóricamente fundamentado, el cual interpreta el capital de una persona o empresa como una opción de compra sobre sus activos de modo que permite estimar las probabilidades de impago a partir de los mismos niveles de deuda y la volatilidad del valor de sus activos (P. s. , 2023). La teoría fue determinante en el desarrollo de las regulaciones de capital regulado por riesgo (Acuerdos de Basilea II), aunque su adopción en economías emergentes es escasa por el mal desarrollo de los mercados de capitales (Kowsar, 2022).

2.2. Métodos de machine Learning: Se clasifican en modelos de aprendizaje supervisado (que usan datos etiquetados para hacer clasificación o regresión) y aprendizaje no supervisado (que pueden agrupar o identificar patrones sin necesidad de etiquetas preexistentes). La principal desventaja es complejidad de su funcionamiento (Paz et al., 2025). Entre los principales modelos de ML están:

- A. Árboles de Decisión: Son estructuras jerárquicas que descomponen el scoring en nodos de decisión de acuerdo con características del cliente como ingresos, deuda, historial de pagos, etc. Son fácilmente interpretables y explicativos ya que la estructura de los árboles se puede representar gráficamente (Machado & Karray, 2022). Además, son capaces de capturar relaciones complejas y se utilizan como un componente base en un conjunto de métodos. Tienen la desventaja de ser propensos al sobreajuste (Bhuiyan & Sweet, 2025).
- B. Métodos de Boosting (XGBoost, LightGBM, CatBoost): Son algoritmos de conjunto que construyen de forma secuencial un modelo fuerte corrigiendo los errores de los modelos anteriores. XGBoost (eXtreme Gradient Boosting) es una de las implementaciones más precisas y eficientes (Amato et al., 2024). Proporcionan una mayor capacidad predictiva y de precisión, superando continuamente a los modelos individuales. XGBoost se utiliza para la linealización y transformación de atributos antes de ser utilizados el conjunto de datos en redes neuronales profundas (Proyag Pal et al., 2025).



- C. Máquinas de Soporte Vectorial (SVM): Son clasificadores muy eficaces que transforman datos no linealmente separables a un espacio de mayor dimensión (a través de funciones kernel) para encontrar un hiperplano óptimo, que maximiza el margen de separación entre clases (cumplidores e incumplidores). Ofrecen una alta precisión de clasificación, superando en muchas ocasiones a la regresión logística. Se han utilizado ampliamente en análisis de riesgo de crédito y son resilientes para casos de datos limitados o dispersos. Su principal desafío es la falta de interpretabilidad (Bhuiyan & Sweet, 2025).
- D. Bosques aleatorios: Método de conjuntos (ensemble) que combina las predicciones de varios árboles entrenados en subconjuntos aleatorios de datos. Esto, como en cualquier método de conjunto, permite reducir la varianza y mejora la robustez de los modelos (Stanley Chidiozie Umeorah et al., 2024). Se consideran uno de los mejores modelos para estimar el riesgo crediticio, junto con los métodos de Boosting. Se utilizan para la predicción de incumplimiento de pago y son eficientes en el tratamiento de valores atípicos y datos ruidosos (Zhang et al., 2024).
- E. Redes Neuronales Artificiales (ANN): Inspiradas en la estructura del cerebro, tienen la capacidad de aprender patrones no lineales y complejas interacciones entre variables predictoras (Faheem, 2021).
- F. Redes Neuronales Profundas (DNN): Tienen múltiples capas ocultas, lo que les permite extraer automáticamente representaciones jerárquicas de las características de los datos. Son ideales para el tratamiento de grandes volúmenes de datos, incluyendo información no estructurada o no lineal (Liu et al., 2022).
- G. LSTM (Long Short-Term Memory): Son usadas para el análisis de riesgo crediticio, principalmente, por su capacidad de procesar y modelar datos secuenciales y dependencias temporales, lo cual es fundamental ya que el comportamiento crediticio de un prestatario cambia con el tiempo (Milojević & Redzepagic, 2021). Las LSTM abordan problemas como la desaparición y explosión de gradientes en procesos de secuenciales a largo plazo mejor que las RNN tradicionales, garantizando que el modelo pueda aprender patrones de pago o tendencias financieras (Shi et al., 2022).

3. Aplicación de técnicas de ML

En esta sección se clarifica las aplicaciones, técnicas, algoritmos, modelos y su funcionamiento. Se clasifican los más usadas. Se analiza el tratamiento de datos e ingeniería de características que usan los algoritmos, la evaluación y métricas de los modelos, los principales desafíos y finalmente los tipos de datos y contexto de aplicación.

3.1. Clasificación de Técnicas

Los métodos se clasifican según su complejidad y capacidad para modelar datos no relacionales. El objetivo en común de todos los siguientes métodos es dar una predicción binaria (cumplimiento o incumplimiento de una obligación) (Bussmann et al., 2021). En el siguiente diagrama se observa la clasificación:

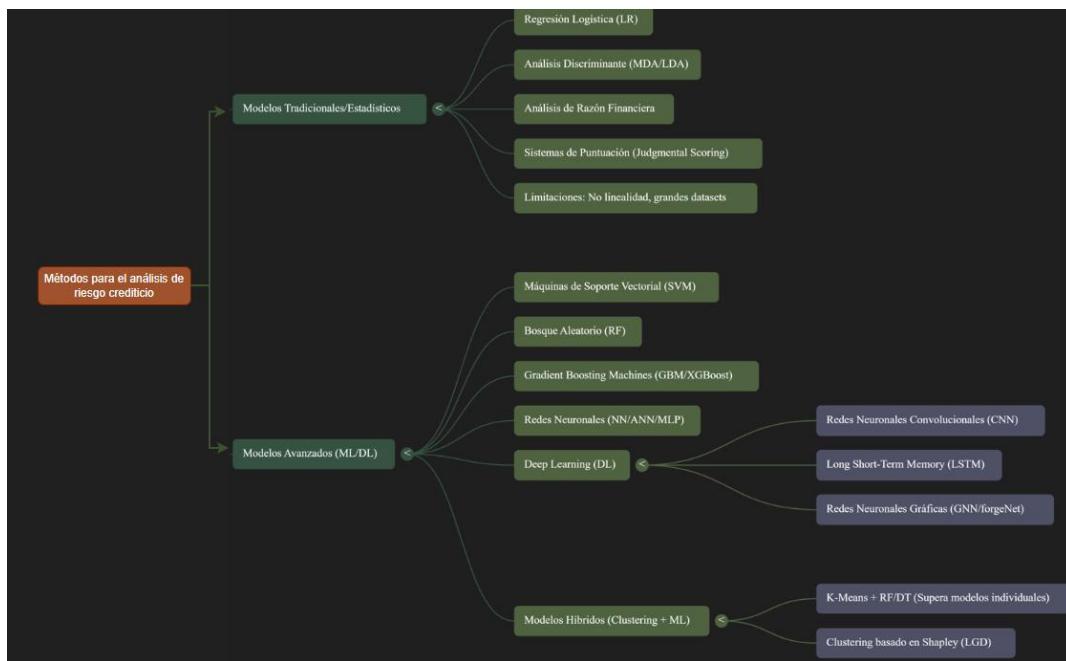


Figura 6 : Clasificación de métodos de análisis de riesgo crediticio

3.2. Tratamiento de datos e ingeniería de características

La eficacia de los modelos depende de la calidad de datos de entrada y el preprocesamiento que se hace para transformarlos en características informativas, para esto se debe tener en cuenta lo siguiente:

- **Manejo de desbalanceados y datos faltantes:** Para la imputación de datos faltantes se usan los valores de media, mediana o moda (Paz et al., 2025). Para el problema de desbalanceo se usan técnicas como SMOTE (Synthetic Minority Oversampling Technique) para generar muestras sintéticas para la clase minoritaria, equilibrando el conjunto de datos y mejorando el rendimiento del modelo (Gasmi et al., 2025).
- **Selección e ingeniería de características:** Es fundamental para comprender el funcionamiento de los modelos y mejorar el rendimiento. Existen tres métodos de selección, el primero es el Filtro se encarga de evaluar la relevancia de las características a partir de propiedades estadísticas. El segundo es la envoltura y evalúa subconjuntos de características a partir del rendimiento que proporcionan entrenando un algoritmo de ML específico. El ultimo es el embobido que realiza la selección de características durante el proceso de entrenamiento (Bouteraa et al., 2024).



- **Modelado de componentes latentes:** Se pueden usar autoencoders variacionales (VAE) para extraer representaciones latentes de datos secuenciales, capturando patrones de comportamiento dinámicos (Fathy, 2024)

3.3. Validación del modelo y métricas de evaluación

La evaluación rigurosa de los modelos es fundamental, ya que las entidades financieras deben garantizar que los modelos sean robustos y confiables (Fathy, 2024). Por esta razón se aplican las siguientes métricas:

- **Métricas de clasificación:** A continuación, se describen las métricas más comunes:
 - Área bajo la curva (AUC-ROC): mide la capacidad del modelo para distinguir entre clases y resulta independiente del umbral de decisión. Un valor más alto (cercano a 1) indica mejor discriminación. El AUC se calcula con la siguiente formula:

$$AUC = \frac{1 + \frac{TP}{FN + TP} - \frac{FP}{TN + FP}}{2}$$

Donde TP = Verdaderos Positivos, TN = Verdaderos Negativos, FP = Falsos Positivos, FN = Falsos Negativos

- **Precisión (Accuracy):** Mide la proporción de instancias que fueron clasificadas correctamente. El ACC se calcula con la siguiente formula:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN}$$

Donde TP = Verdaderos Positivos, TN = Verdaderos Negativos, FP = Falsos Positivos, FN = Falsos Negativos

- **Precisión (precision):** Mide la proporción de predicciones positivas correctas.
- **Sensibilidad (Recall/Sensitivity):** Mide la proporción de los casos positivos reales correctamente identificados.
- **Puntuación F1 (F1-Score):** Media armónica de precisión y recuerdo, útil para conjuntos de datos desequilibrados (Noriega et al., 2023).
- **G-Mean:** Promedio geométrico de sensibilidad y especificidad, útil para medir el rendimiento con respecto a los datos desbalanceados.



- **Métricas de regresión:** Usadas para predecir el puntaje crediticio en un valor continuo, las más comunes son:
 - Error cuadrático medio (MSE/RMSE): mide la magnitud promedio del error en las predicciones (al cuadrado).
 - Error absoluto medio (MAE): mide la magnitud promedio de los errores en las predicciones.
 - Varianza explicada (EV) o R^2 : mide la proporción de la varianza total explicada por el modelo (Bosker et al., 2025).

3.4. Técnicas de validación

Gran parte de los modelos usan la validación cruzada (cross-validation) como k-fold cross-validation o 5×2 cross-validation paired t-test, se utiliza para asegurar la solidez del modelo y evitar el sobreajuste del modelo. La prueba de estrés evalúa la robustez del modelo bajo escenarios adversos como las contracciones del PIB o las subidas de la tasa de interés (Wei, 2023).

3.5. Tipos de datos y contextos de aplicación

Los tipos de datos pueden variar según el campo de aplicación, así como también el origen de estos.

- **Fuentes de datos:** Para el sector financiero los datos tradicionales provienen de historiales crediticios, informes buro y estados financieros (Wilhelmina Afua Addy et al., 2024). Para los datos alternativos el ML permite incorporar una gama más ampliada de datos no tradicionales, lo cual es crucial para la inclusión financiera de poblaciones discriminadas, algunos ejemplos son transacciones en tiempo real, actividades en redes sociales, pago de facturas (Doumpos et al., 2023), etc (Hussain et al., 2024).
- **Contextos de aplicación:** Para el caso del crédito comercial se centra en variables financieras (balances, ratios), clasificación de la empresa y datos transaccionales (Zhu et al., 2024). Otro campo de aplicación es el crédito minorista que se enfoca en préstamos personales, hipotecas individuales y tarjetas de crédito (Tewari et al., 2023). Por otra parte, para las finanzas de la cadena de suministros que Utiliza modelos de ML para evaluar el riesgo crediticio en el ecosistema, integrando datos transaccionales y comportamiento de proveedores, compradores y datos logísticos. XGBoost-BiLSTM ha demostrado un rendimiento predictivo más alto en calidad de sus aportaciones al contexto (Ahmed et al., 2022). Por ultimo en las microfinanzas, dadas las limitaciones de datos tradicionales, los modelos de ML se adaptan para utilizar datos alternativos o atributos cualitativos del prestatario, actividades en redes informales y reputación comunitaria (Benfica & Marques, 2024)

4. Conclusión

En el análisis de las 51 investigaciones seleccionadas evidenció un crecimiento sostenido en el uso de la IA en el sector financiero, especialmente en los relacionado con la evaluación del riesgo crediticio. La revisión permitió identificar una evolución metodológica en la que los métodos estadísticos tradicionales de análisis crediticio han sido progresivamente complementados e incluso sustituidos por modelos de ML que permiten procesar grandes volúmenes de datos con mayor precisión y adaptabilidad. Los resultados muestran una ventaja frente al uso de los métodos estadísticos tradicionales, como la regresión logística o el análisis discriminante, estos se destacan por su transparencia, interpretabilidad y fácil de implementación, aspectos que son especialmente relevantes en contextos regulatorios y financieros donde la explicabilidad de los modelos es prioritaria. Sin embargo, las investigaciones más recientes evidencian el crecimiento en el uso de modelos o de ML, como árboles de decisión, redes neuronales, máquinas de soporte vectorial y modelos de ensamblaje, que ofrecen una mejor capacidad predictiva y una mejor gestión de variables complejas y no lineales.

El estudio también permitió identificar tendencias complementarias que amplían la comprensión del rol de la IA en el ámbito financiero. Por ejemplo, varios trabajos abordan la industria4.0, enfatizando la integración de la IA en sistemas financieros inteligentes y automatizados. Otros estudios analizan el impacto ambiental derivado del uso intensivo de la tecnológica IA, subrayando la necesidad de enfoques más eficientes en términos energéticos y proponiendo la implementación de marcos regulatorios. Diferentes artículos exploran la gobernanza y la regulación de la IA, enfatizando la valoración de establecer marcos éticos y normativos para el uso responsable, seguro y transparente de esta tecnología en el sistema financiero.

Desde el punto de vista técnico, se observó que los trabajos más avanzados tienen procesos rigurosos de evaluación y validación, así como una creciente atención por el tratamiento, calidad y diversidad de los datos empleados. No obstante, también se advirtió que la eficacia de los modelos de ML depende, en gran medida, de la disponibilidad, representatividad y seguridad de la información financiera utilizada, planteando desafíos en materias de privacidad, sesgo algorítmico y cumplimiento normativo.

En síntesis, el análisis comparativo realizado sugiere que los métodos de Machine Learning pueden lograr un desempeño superior a los métodos tradicionales en la estimación del riesgo crediticio, principalmente por la capacidad para detectar patrones complejos y mejorar la precisión predictiva. Sin embargo, la adopción de tales métodos en servicios financieros debe considerar cuidadosamente criterios regulatorios, la interpretabilidad de los modelos, y también las implicaciones éticas y operativas de su integración en sectores financieros. En consecuencia, se concluye que el verdadero desafío no está exclusivamente en la elección del modelo más preciso, sino en encontrar un equilibrio entre responsabilidad tecnológica, eficiencia y transparencia, de forma que la IA contribuya efectivamente a la sostenibilidad, progreso, equidad y confianza en el sistema financiero contemporáneo.



8. Referencias bibliográficas

- Ahmed, S., Alshater, M. M., Ammari, A. E., & Hammami, H. (2022). Artificial intelligence and machine learning in finance: A bibliometric review. *Research in International Business and Finance*, 61, 101646. <https://doi.org/10.1016/j.ribaf.2022.101646>
- Alzoubi, Y. I., & Mishra, A. (2024). Green artificial intelligence initiatives: Potentials and challenges. *Journal of Cleaner Production*, 468, 143090. <https://doi.org/10.1016/j.jclepro.2024.143090>
- Amato, A., Osterrieder, J. R., & Machado, M. R. (2024). How can artificial intelligence help customer intelligence for credit portfolio management? A systematic literature review. *International Journal of Information Management Data Insights*, 4(2), 100234. <https://doi.org/10.1016/j.jjimei.2024.100234>
- Armagan, I. U. (2023). Price prediction of the Borsa Istanbul banks index with traditional methods and artificial neural networks. *Borsa Istanbul Review*, 23, S30-S39. <https://doi.org/10.1016/j.bir.2023.10.005>
- Bahoo, S., Cucculelli, M., Goga, X., & Mondolo, J. (2024). Artificial intelligence in Finance: A comprehensive review through bibliometric and content analysis. *SN Business & Economics*, 4(2), 23. <https://doi.org/10.1007/s43546-023-00618-x>
- Beckmann, L., & Hark, P. F. (2024). ChatGPT and the banking business: Insights from the US stock market on potential implications for banks. *Finance Research Letters*, 63, 105237. <https://doi.org/10.1016/j.frl.2024.105237>
- Belli, L., & Zingales, N. (2022). Data protection and artificial intelligence inequalities and regulations in Latin America. *Computer Law & Security Review*, 47, 105761. <https://doi.org/10.1016/j.clsr.2022.105761>
- Benfica, V., & Marques, A. C. (2024). Technological and financial development as drivers of Latin America's energy transition. *Renewable Energy*, 237, 121664. <https://doi.org/10.1016/j.renene.2024.121664>
- Berrada, I. R., Barramou, F. Z., & Alami, O. B. (2022). A review of Artificial Intelligence approach for credit risk assessment. *2022 2nd International Conference on Artificial Intelligence and Signal Processing (AISP)*, 1-5. <https://doi.org/10.1109/AISP53593.2022.9760655>
- Bhuiyan, M., & Sweet, M. M. R. (2025). Credit Risk Assessment Using Statistical and Machine Learning: Basic Methodology and Risk Modeling Applications. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.5068722>
- Bosker, J., Gürtler, M., & Zöllner, M. (2025). Machine learning-based variable selection for clustered credit risk modeling. *Journal of Business Economics*, 95(4), 617-652. <https://doi.org/10.1007/s11573-024-01213-8>
- Bouteraa, M., Chekima, B., Thurasamy, R., Bin-Nashwan, S. A., Al-Daihani, M., Baddou, A., Sadallah, M., & Ansar, R. (2024). Open Innovation in the Financial Sector: A Mixed-Methods Approach to Assess Bankers' Willingness to Embrace Open-AI ChatGPT. *Journal of Open Innovation: Technology, Market, and Complexity*, 10(1), 100216. <https://doi.org/10.1016/j.joitmc.2024.100216>



- Bussmann, N., Giudici, P., Marinelli, D., & Papenbrock, J. (2021). Explainable Machine Learning in Credit Risk Management. *Computational Economics*, 57(1), 203-216. <https://doi.org/10.1007/s10614-020-10042-0>
- Cruz Salazar, L. A., Gil, S., Rueda Carvajal, G. D., Sánchez-Zuluaga, G. J., & Zapata-Madrigal, G. D. (2024). AI in assessing Industry 4.0 adoption in Colombia: A case study approach. *IFAC-PapersOnLine*, 58(8), 162-167. <https://doi.org/10.1016/j.ifacol.2024.08.067>
- Cubric, M., & Li, F. (2024). Bridging the ‘Concept–Product’ gap in new product development: Emerging insights from the application of artificial intelligence in FinTech SMEs. *Technovation*, 134, 103017. <https://doi.org/10.1016/j.technovation.2024.103017>
- Doumpos, M., Zopounidis, C., Gounopoulos, D., Platanakis, E., & Zhang, W. (2023). Operational research and artificial intelligence methods in banking. *European Journal of Operational Research*, 306(1), 1-16. <https://doi.org/10.1016/j.ejor.2022.04.027>
- Faheem, M. A. (2021). *AI-Driven Risk Assessment Models: Revolutionizing Credit Scoring and Default Prediction*. Unpublished. <https://doi.org/10.13140/RG.2.2.21281.01128>
- Fathy, T. (2024). *Artificial Intelligence and Predictive Data Analytics to Enhance Risk Assessment and Credit Scoring Mechanisms in Retail Banking*.
- Fatima, S., & Chakraborty, M. (2024). Adoption of artificial intelligence in financial services: The case of robo-advisors in India. *IIMB Management Review*, 36(2), 113-125. <https://doi.org/10.1016/j.iimb.2024.04.002>
- Gasmi, I., Neji, S., Mansouri, N., & Soui, M. (2025). Bank credit risk prediction using machine learning model. *Neural Computing and Applications*, 37(16), 10333-10350. <https://doi.org/10.1007/s00521-025-11044-5>
- Hajipour, V., Hekmat, S., & Amini, M. (2023). A value-oriented Artificial Intelligence-as-a-Service business plan using integrated tools and services. *Decision Analytics Journal*, 8, 100302. <https://doi.org/10.1016/j.dajour.2023.100302>
- Hussain, S., Bharathy, G., & Aziz, S. (2024). *Explainable Artificial Intelligence in Financial Services: A Case Study on Credit Card Delinquency*. SSRN. <https://doi.org/10.2139/ssrn.4930148>
- Kiran, A., Gongada, T. N., Arangi, V., Ahmad, A. Y. A. B., Dhabliya, D., & Gupta, A. (2023). Assessing the Performance of Machine Learning Algorithms for Credit Risk Assessment. *2023 3rd International Conference on Advancement in Electronics & Communication Engineering (AECE)*, 881-886. <https://doi.org/10.1109/AECE59614.2023.10428359>
- Kowsar, M. (2022). A SYSTEMATIC REVIEW OF CREDIT RISK ASSESSMENT MODELS IN EMERGING ECONOMIES: A FOCUS ON BANGLADESH’S COMMERCIAL BANKING SECTOR. *American Journal of Advanced Technology and Engineering Solutions*.
- Lappas, P. Z., & Yannacopoulos, A. N. (2021). A machine learning approach combining expert knowledge with genetic algorithms in feature selection for credit risk assessment. *Applied Soft Computing*, 107, 107391. <https://doi.org/10.1016/j.asoc.2021.107391>
- Liu, J., Zhang, S., & Fan, H. (2022). A two-stage hybrid credit risk prediction model based on XGBoost and graph-based deep neural network. *Expert Systems with Applications*, 195, 116624. <https://doi.org/10.1016/j.eswa.2022.116624>
- Machado, M. R., & Karray, S. (2022). Assessing credit risk of commercial customers using hybrid machine learning algorithms. *Expert Systems with Applications*, 200, 116889. <https://doi.org/10.1016/j.eswa.2022.116889>



- Malik, S., Muhammad, K., & Waheed, Y. (2024). Artificial intelligence and industrial applications- A revolution in modern industries. *Ain Shams Engineering Journal*, 15(9), 102886. <https://doi.org/10.1016/j.asej.2024.102886>
- Mi Alnaser, F., Rahi, S., Alghizzawi, M., & Ngah, A. H. (2023). Does artificial intelligence (AI) boost digital banking user satisfaction? Integration of expectation confirmation model and antecedents of artificial intelligence enabled digital banking. *Helijon*, 9(8), e18930. <https://doi.org/10.1016/j.helijon.2023.e18930>
- Milojević, N., & Redzepagic, S. (2021). Prospects of Artificial Intelligence and Machine Learning Application in Banking Risk Management. *Journal of Central Banking Theory and Practice*, 10(3), 41-57. <https://doi.org/10.2478/jcbtp-2021-0023>
- Noriega, J. P., Rivera, L. A., & Herrera, J. A. (2023). Machine Learning for Credit Risk Prediction: A Systematic Literature Review. *Data*, 8(11), Article 11. <https://doi.org/10.3390/data8110169>
- Navarro Pino, D., Badillo Rincón, J. S., Portillo Padilla, M. D., & Pineda Aguilera, S. E. (2024). *Tecnologías y herramientas del internet de las cosas (IoT) para el desarrollo de prototipos de entornos cotidianos*. Revista Colombiana de Tecnologías de Avanzada (RCTA), 2(44), 97–103. <https://doi.org/10.24054/rcta.v2i44.3020>
- Pattnaik, D., Ray, S., & Raman, R. (2024). Applications of artificial intelligence and machine learning in the financial services industry: A bibliometric review. *Helijon*, 10(1), e23492. <https://doi.org/10.1016/j.helijon.2023.e23492>
- Paz, Á., Crawford, B., Monfroy, E., Barrera-García, J., Peña Fritz, Á., Soto, R., Cisternas-Caneo, F., & Yáñez, A. (2025). Machine Learning and Metaheuristics Approach for Individual Credit Risk Assessment: A Systematic Literature Review. *Biomimetics*, 10(5), 326. <https://doi.org/10.3390/biomimetics10050326>
- Polireddi, N. S. A. (2024). An effective role of artificial intelligence and machine learning in banking sector. *Measurement: Sensors*, 33, 101135. <https://doi.org/10.1016/j.measen.2024.101135>
- Pozzo, D. N., Gonzalez Beleño, C. A., Correa, K. R., Donado, M. G., Gomez Pedroza, F. J., & Moncada Diaz, J. E. (2024). Managers' attitudes and behavioral intentions towards using artificial intelligence for organizational decision-making: A study with Colombian SMEs. *Procedia Computer Science*, 238, 956-961. <https://doi.org/10.1016/j.procs.2024.06.119>
- Proyag Pal, Zhiyuan Wang, Xu Zhu, Jiajia Chew, Katarzyna Prus, & Xiangang Wei. (2025). *AI-Based Credit Risk Assessment and Intelligent Matching Mechanism in Supply Chain Finance*. <https://doi.org/10.5281/ZENODO.15368771>
- P. s. , Dr. V. (2023). How can we manage biases in artificial intelligence systems – A systematic literature review. *International Journal of Information Management Data Insights*, 3(1), 100165. <https://doi.org/10.1016/j.jjimei.2023.100165>
- Rizal, N. A. (2024). Artificial Intelligence in Finance. En *Reference Module in Social Sciences*. Elsevier. <https://doi.org/10.1016/B978-0-443-13701-3.00030-X>
- Rodrigues, A. R. D., Ferreira, F. A. F., Teixeira, F. J. C. S. N., & Zopounidis, C. (2022). Artificial intelligence, digital transformation and cybersecurity in the banking sector: A multi-stakeholder cognition-driven framework. *Research in International Business and Finance*, 60, 101616. <https://doi.org/10.1016/j.ribaf.2022.101616>
- Sadok, H., Sakka, F., & El Maknouzi, M. E. H. (2022). Artificial intelligence and bank credit analysis: A review. *Cogent Economics & Finance*, 10(1), 2023262. <https://doi.org/10.1080/23322039.2021.2023262>



- Shi, S., Tse, R., Luo, W., D'Addona, S., & Pau, G. (2022). Machine learning-driven credit risk: A systemic review. *Neural Computing and Applications*, 34(17), 14327-14339. <https://doi.org/10.1007/s00521-022-07472-2>
- Singh, J., Singh, G., Gahlawat, M., & Prabha, C. (2022). Big Data as a Service and Application for Indian Banking Sector. *Procedia Computer Science*, 215, 878-887. <https://doi.org/10.1016/j.procs.2022.12.090>
- Stanley Chidozie Umeorah, Adesola Oluwatosin Adelaja, Bibitayo Ebunlomo Abikoye, Oluwatoyin Funmilayo Ayodele, & Yewande Mariam Ogunsuji. (2024). Data-driven credit risk monitoring: Leveraging machine learning in risk management. *Finance & Accounting Research Journal*, 6(8), 1416-1435. <https://doi.org/10.51594/farj.v6i8.1399>
- Tao, M. (2024). Digital brains, green gains: Artificial intelligence's path to sustainable transformation. *Journal of Environmental Management*, 370, 122679. <https://doi.org/10.1016/j.jenvman.2024.122679>
- Tewari, I., Bisht, S., Tiwari, A., Joshi, B., Arora, S., & Tewari, G. (2023). The Revolutionary Transformation of India's Banking Industry through Artificial Intelligence. *2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, 1-5. <https://doi.org/10.1109/ICCCNT56998.2023.10307322>
- Tóth, Z., & Blut, M. (2024). Ethical compass: The need for Corporate Digital Responsibility in the use of Artificial Intelligence in financial services. *Organizational Dynamics*, 53(2), 101041. <https://doi.org/10.1016/j.orgdyn.2024.101041>
- Trzaska, R., & Sus, A. (2023). Industry 4.0 business strategic risks based on the scalability 4.0 concept. Artificial Intelligence area. *Procedia Computer Science*, 225, 3255-3264. <https://doi.org/10.1016/j.procs.2023.10.319>
- Wei, Y. (2023). Application of Machine Learning and Artificial Intelligence in Credit Risk Assessment. *2023 2nd International Conference on Artificial Intelligence and Autonomous Robot Systems (AIARS)*, 150-156. <https://doi.org/10.1109/AIARS59518.2023.00037>
- Wilhelmina Afua Addy, Chinonye Esther Ugochukwu, Adedoyin Tolulope Oyewole, Onyeka Chrisanctus Ofodile, Omotayo Bukola Adeoye, & Chinwe Chinazo Okoye. (2024). Predictive analytics in credit risk management for banks: A comprehensive review. *GSC Advanced Research and Reviews*, 18(2), 434-449. <https://doi.org/10.30574/gscarr.2024.18.2.0077>
- Zhang, X., Xu, L., Li, N., & Zou, J. (2024). *Research on Credit Risk Assessment Optimization Based on Machine Learning*. Computer Science and Mathematics. <https://doi.org/10.20944/preprints202407.1349.v1>
- Zhu, H., Vigren, O., & Söderberg, I.-L. (2024). Implementing artificial intelligence empowered financial advisory services: A literature review and critical research agenda. *Journal of Business Research*, 174, 114494. <https://doi.org/10.1016/j.jbusres.2023.114494>