




Modelos para la evaluación de riesgo crediticio en el ámbito de la tecnología financiera: una revisión

Credit Risk Assessment Models in Financial Technology: A Review

  Frank Edward Tadeo Espinoza¹;
 Marco Antonio Coral Ygnacio²

¹Universidad Católica Sedes Sapientiae, Ventanilla–Perú,
2018100090@ucss.pe

²Universidad Católica Sedes Sapientiae, Lima–Perú,
mcoral@ucss.edu.pe

ISSN-p: 0123-7799
ISSN-e: 2256-5337

Vol. 26, nro. 58, e2679, 2023

Recibido: 24 marzo 2023
Aceptado: 30 octubre 2023
Disponible: 20 diciembre 2023

©Instituto Tecnológico Metropolitano
Este trabajo está licenciado bajo
una Licencia Internacional
Creative Commons Atribución
(CC BY-NC-SA)



How to cite / Cómo citar

F. E. Tadeo Espinoza, M. A. Coral Ygnacio, “Modelos para la evaluación de riesgo crediticio en el ámbito de la tecnología financiera: una revisión,” *Tecnológicas*, vol. 26, nro. 58, e2679, 2023.
<https://doi.org/10.22430/22565337.2679>

Resumen

Esta revisión analiza una selección de artículos científicos sobre la implantación de sistemas de evaluación del riesgo de crédito para identificar las soluciones existentes, las más acertadas y las limitaciones y problemas en su desarrollo. Se adoptó la declaración PRISMA del siguiente modo: se formularon las preguntas de investigación, se definieron los criterios de inclusión, se seleccionaron las palabras clave y se diseñó la cadena de búsqueda. Por último, se calcularon varios estadísticos descriptivos de los artículos seleccionados. En los estudios seleccionados se identificaron 31 soluciones, entre métodos, modelos y algoritmos. Algunos de los modelos más utilizados se basan en técnicas de Inteligencia Artificial (IA), especialmente Redes Neuronales y Bosques Aleatorios. Se concluyó que las Redes Neuronales son las soluciones más eficientes, con precisiones medias superiores al 90 %, pero su desarrollo puede tener limitaciones. Estas soluciones deben implementarse teniendo en cuenta el contexto en el que se van a emplear.

Palabras clave

Evaluación crediticia, riesgo de crédito, soluciones tecnológicas, aprendizaje automático, algoritmos.

Abstract

This review analyzes a selection of scientific articles on the implementation of Credit Risk Assessment (CRA) systems to identify existing solutions, the most accurate ones, and limitations and problems in their development. The PRISMA statement was adopted as follows: the research questions were formulated, the inclusion criteria were defined, the keywords were selected, and the search string was designed. Finally, several descriptive statistics of the selected articles were calculated. Thirty-one solutions were identified in the selected studies; they include methods, models, and algorithms. Some of the most widely used models are based on Artificial Intelligence (AI) techniques, especially Neural Networks and Random Forest. It was concluded that Neural Networks are the most efficient solutions, with average accuracies above 90 %, but their development can have limitations. These solutions should be implemented considering the context in which they will be employed.

Palabras clave

Credit assessment, credit risk, technology solutions, machine learning, algorithms.

1. INTRODUCCIÓN

El riesgo crediticio se puede definir como la clasificación o evaluación que se realiza a una persona que presenta una solicitud de crédito a una entidad bancaria. Estos sistemas tienen como función principal afrontar el problema de clasificación del cliente en función a su comportamiento o historial crediticio [1] y varían en función a las variables que se deseen considerar dentro del proceso de evaluación de riesgo como cuentas morosas, el saldo de otros préstamos, características de las cuentas personales, los ingresos mensuales y datos demográficos, como la edad y el estado civil [2]. Este problema ha estado presente desde hace muchos años, pero, más recientemente y debido a la pandemia del Covid-19, esta problemática ha incrementado significativamente debido al gran número de solicitudes presentadas, esto a causa de que muchas personas recurrieron a solicitar créditos bancarios, muchas de las cuales contaban con un pésimo historial crediticio o simplemente solicitaban montos superiores a los que podrían devolver, debido a ello la evaluación pertinente ante el riesgo de impago del cliente presenta deficiencias que generan pérdidas a las entidades debido al gran número de deudores y, a pesar de la paulatina vuelta a la normalidad el número sigue en aumento, por lo cual se genera la necesidad de desarrollar diversas y más eficientes soluciones a fin de minimizar las pérdidas [3].

Todo lo anterior mencionado, describe la problemática encontrada con respecto a la evaluación de riesgo crediticio, por tanto, la adopción de nuevas y rentables tecnologías que permitan que dichos sistemas pueden ser implementados, permitiría a estas entidades lograr contar con un sistema de soporte en la toma de decisiones para el otorgamiento de los créditos financieros que se les pueda solicitar [4]. Es en este sentido donde los sistemas de evaluación de riesgo crediticio surgen como alternativa viable para mejorar los procesos de evaluación para el otorgamiento de crédito, se ha comenzado a desarrollar cada vez más rápido, diferentes sistemas de evaluación de riesgo crediticio aplicando muchas de las tecnologías disponibles en la actualidad, muchos de los bancos se encuentran desarrollando sistemas propios basados en sus propios criterios de selección a fin de reducir el porcentaje de probabilidad de pérdida frente a los préstamos que pueda solicitar un cliente o empresa [5]. Entre las soluciones más utilizadas se tiene a los sistemas de evaluación de riesgo crediticio los cuales están basados en técnicas de inteligencia artificial y aprendizaje automático que analizan y seleccionan tendencias sobre los posibles candidatos a convertirse en deudores potenciales [6]. Estas soluciones han demostrado ser eficientes, pero dependen de diferentes factores: los datos requeridos, a los cuales muchas veces no tiene acceso todas las entidades financieras sobre todo las microfinancieras y no contemplan variables tales como factores demográficos que mejorarían los resultados de los sistemas, los estándares, los cuales actualmente no son exigidas para definir el tratamiento de datos como soluciones. A partir de las soluciones de evaluación de riesgo crediticio se busca mejorar los procesos de evaluación y con ello reducir las pérdidas económicas para las entidades [7].

Estos procesos de evaluación de riesgo crediticio pueden desarrollarse utilizando métodos, modelos o algoritmos tecnológicos que permitan realizar los procesos de predicción y selección [8]. Por medio de ellos, se trata de crear modelos computacionales que representen los procesos de selección de clientes para el otorgamiento de créditos financieros que realizan los bancos actualmente a fin de brindar un enfoque más claro y con mejores resultados [9]. El funcionamiento de estas herramientas de evaluación se basa en la aplicación de diversos modelos estadísticos, dependiendo de la complejidad de la evaluación.

Estos modelos estadísticos son empleados para el tratamiento de los datos siendo el modelo SMOTE (por sus siglas en inglés) el más utilizado dentro de los sistemas de evaluación [10]–[12], el modelo se basa en la aplicación de algoritmos y procesos matemáticos

para la generación artificial de muestras sintéticas, es decir, muestras artificiales generadas a partir de las características de las muestras originales de las clases evaluadas, permitiendo generar muestras más generales y más equilibradas para su tratamiento [13]. Además del modelo mencionado, la eficiencia de cada tipo de modelo estadístico varía en función al enfoque y al modelo que desarrollan los investigadores, los cuales desarrollan sus propias medidas de eficiencia con la cual evalúan cada uno de los aspectos que se crea conveniente [14]. Además de ello, dichos procesos de evaluación pueden variar dependiendo de la entidad financiera y de los modelos financieros que estas utilicen, esto debido a que las variables con las que las entidades miden el nivel del riesgo pueden cambiar dependiendo del enfoque que la entidad requiera [15].

Por otro lado, en el desarrollo de sistemas de evaluación de riesgo crediticio se destaca el uso de técnicas de inteligencia artificial para el procesamiento y clasificación de los datos, sustituyendo el análisis humano con la finalidad de mejorar la precisión y rapidez con la que son evaluados. Estos sistemas clasifican en base a predicciones el nivel de riesgo asociado al otorgamiento de créditos financieros evaluando diversas variables como: factores económicos, factores sociales, factores demográficos, factores financieros, etc. [16].

Los sistemas de evaluación de riesgo crediticio aparecieron a comienzos de los años 2000 con el desarrollo de nuevas tecnologías y con la necesidad de las financieras de contar con un sistema de información capaz de realizar dicha evaluación, inicialmente se desarrollaron sistemas basados en algoritmos y técnicas estadísticas con base de modelos financieros a fin de determinar deudores potenciales [17]. Con el tiempo aparecieron los sistemas basados en Aprendizaje Automático, los cuales evolucionaron a modelos de inteligencia artificial haciendo uso de técnicas de Big Data para el procesamiento de grandes bases de datos necesarias para un mejor resultado de evaluación [18].

La implementación de sistemas de evaluación de riesgo crediticio involucra, además, el uso de diversos modelos financieros los cuales deben ser comparados y validados con las bases teóricas necesarias a fin de generar soluciones confiables, estas soluciones además involucran modelos estadísticos para el tratamiento de grandes cantidades de datos, ello se requiere para mejorar los procesos de implementación de los sistemas a fin de mejorar continuamente el desarrollo de estas soluciones [19].

La literatura especializada recomienda para la implementación de estos sistemas el uso y aplicación de técnicas de Aprendizaje Automático (Machine Learning), sobre todo algoritmos basados en Random Forest debido a su nivel de predicción teniendo en cuenta diversos factores, también se determinan técnicas de inteligencia artificial, siendo las soluciones más utilizadas las basadas en redes neuronales que combinan tanto algoritmos estadísticos como procesos algorítmicos. Además, la literatura hace referencia a tener en cuenta la parte del hardware el cual debe ser adecuado dependiendo del nivel requerido para ejecutar el procesamiento de los algoritmos [20].

Para la implementación de estos sistemas es necesario contar con modelos que determinen las variables que se requieren evaluar, pero la mayoría de los trabajos revisados describe pocas soluciones donde se muestra la lógica de la evaluación crediticia. Además, existe poca información acerca de las limitaciones asociadas a la implementación de estos sistemas.

Para el desarrollo del tema de estudio se plantean 4 preguntas de investigación orientadas a determinar los métodos, modelos y algoritmos empleados en sistemas de evaluación de riesgo crediticio, la eficiencia de cada uno de ellos, los modelos para la lógica de la evaluación, y las limitaciones que están presentes en el desarrollo de los sistemas de evaluación de riesgo crediticio.

Se requiere conocer las diferentes soluciones utilizadas en la construcción de sistemas de evaluación crediticia que han demostrado una mayor eficiencia en sus resultados, de igual

manera se pretende conocer y analizar las limitaciones y problemas asociadas al desarrollo de sistemas de evaluación.

El presente trabajo desarrolla una revisión sistemática de literatura basada en la declaración PRISMA, la cual nos brindan los parámetros para realizar de manera organizada y sistemática el conocimiento relacionado al tema de investigación [21].

La revisión sistemática de literatura identifica 41 soluciones más utilizadas en la implementación de estos sistemas de evaluación, de los cuales 10 son técnicas basadas en modelos financieros, también se determinaron 3 limitaciones o problemas que pueden surgir durante el desarrollo de la implementación, uno de ellos de carácter significativo que debe ser tomado en consideración una vez terminado el proceso de implementación.

El trabajo está organizado de manera jerárquica, el primer apartado muestra la introducción del trabajo seguido el estado del arte, el segundo apartado desarrolla la metodología de la revisión sistemática de literatura y presenta el análisis estadístico de los datos recabados, el tercer apartado presenta los resultados a las preguntas de investigación planteadas en la revisión, y en el último apartado se presentan las conclusiones de la revisión seguido por la respectiva bibliografía.

2. METODOLOGÍA

Para la realización de la presente revisión se emplea la metodología PRISMA con la finalidad de estudiar todo los conocimientos e investigaciones relacionadas con el tema de investigación. Esta metodología busca brindar a los investigadores un marco de referencia con la finalidad de desarrollar la revisión sistemática de una manera correcta y que sea aceptada por toda la comunidad científica. De igual manera, la metodología PRISMA permite a los investigadores contar con pasos diseñados para la realización de su revisión sistemática de literatura, permitiendo determinar objetivos, criterios de elegibilidad, resultados y conclusiones [21]. Empleando los pasos PRISMA, se determinó el protocolo bajo el cual se desarrollará la revisión. En dicho protocolo se detalla utilizar 17 pasos de la metodología.

Además de ello, se determinaron los objetivos de la revisión a fin de poder obtener y abarcar toda la información necesaria para el desarrollo de la investigación. Como se puede ver en el Tabla 1, se determinaron 4 objetivos y 4 preguntas de investigación para la revisión sistemática basado en el formato PICO proporcionado por la metodología PRISMA, este formato es una normativa que ofrece la metodología PRISMA para la formulación de preguntas de investigación donde la P significa población o problema, I significa Intervención, la letra C de Comparación o Criterio y, por último, O de Resultado, traducido al español de la palabra Outcome [21]. El primer objetivo es de carácter cuantitativo ya que se determinó con la finalidad de conocer y contabilizar el total de métodos, modelos o algoritmos empleados en la implementación de sistemas de evaluación de riesgo crediticio; los otros 3 objetivos son de carácter cualitativo ya que determinan cuales son los modelos, métodos y algoritmos más eficientes, así como también determina los problemas o limitaciones que pueden surgir durante la implementación del sistema de evaluación de riesgo crediticio. A partir de los objetivos establecidos para la revisión sistemática, se plantearon las preguntas de investigación con la finalidad de brindar una respuesta a los objetivos planteados.

Tabla 1. Objetivos de la RSL. Fuente: elaboración propia.

Objetivo de investigación	Preguntas de investigación	Tipo
Determinar los métodos, modelos y algoritmos utilizados en las implementaciones de sistemas de evaluación de riesgo crediticio.	¿Qué métodos, modelos y algoritmos son utilizados por los sistemas de evaluación de riesgo crediticio?	Cuantitativa
Determinar los métodos, modelos y algoritmos más eficientes para las implementaciones de sistemas evaluación de riesgo crediticio.	¿Qué métodos, modelos y algoritmos son los más eficientes para la implementación de un sistema de evaluación de riesgo crediticio?	Cualitativa
Identificar cuáles son los modelos de riesgo crediticio que utilizan las entidades bancarias.	¿Qué modelos de riesgo crediticio utilizan las entidades bancarias?	Cualitativa
Determinar las limitaciones o problemas que pueden surgir al implementar un sistema de evaluación de riesgo crediticio.	¿Qué problemas o limitaciones pueden surgir al implementar un sistema de evaluación de riesgo crediticio?	Cualitativa

Se prosiguió definiendo la cadena de búsqueda, identificándose tres conjuntos de búsqueda. El primer conjunto involucra los términos relacionados a la implementación de un sistema, es decir los *métodos, modelos, algoritmos y tecnologías*. El segundo conjunto de términos está relacionado al problema que se trata en la investigación, es decir *riesgo crediticio* o *evaluación de riesgo crediticio*. Para el último conjunto de términos se tomó en cuenta lo que se busca realizar para dar solución el problema, es el caso del tema de investigación se considera las palabras *sistema, implementación y software*. Tomando en cuenta esos tres conjuntos de términos se determina la siguiente cadena de búsqueda: (*methods OR models OR algorithms OR technologies*) AND (“*credit risk*” OR “*credit risk assessment*”) AND (*system OR implementation OR software*).

Además, se determinaron seis criterios de inclusión, el primero criterio hace referencia al idioma en el que se publica el artículo, para la revisión solo se tendrá en cuenta todos los artículos que hayan sido publicados en inglés dado que es en este idioma donde se publican artículos aceptados por la comunidad científica. De igual manera el segundo criterio de inclusión hace referencia al año de publicación de los artículos, dado que solo tendrán en consideración artículos publicados entre los años 2018 y 2022, a fin de contar con artículos de años recientes. Además, solo se incluirán artículos que se encuentren en estado terminado y estén en bases de datos indexadas, a fin de garantizar la legitimidad de los artículos. Finalmente, se determinó que solo se incluirán los artículos que traten los temas de implementación de sistemas de evaluación de riesgo crediticio. Todo ello se presenta en la Tabla 2.

Tabla 2. Criterios de inclusión y exclusión. Fuente: elaboración propia.

Criterios de inclusión	Criterios de exclusión
Artículos publicados en inglés	Artículos publicados en años anteriores al 2018
Artículos publicados entre los años 2018 y 2022	Artículos publicados en idiomas que no sean inglés
Artículos de investigación que se encuentren terminados	Artículos de revisión de literatura, metaanálisis o incompletos
Artículos publicados en bases científicas indexadas	Artículos poco relacionados con la implementación de evaluación de riesgo crediticio
Artículos acerca evaluación de riesgo crediticio	Artículos sin DOI
Artículos acerca de la implementación de evaluación de riesgo crediticio	

Una vez definida la cadena de búsqueda y los criterios de inclusión y exclusión, se comenzó con la búsqueda de los artículos, para ello se hizo uso de 3 bases de datos de artículos científicos: Scopus, IEEEExplore y ResearchGate, las cuales fueron utilizadas por el acceso gratuito a los artículos revisados. La búsqueda se realizó el día 13 de septiembre del 2022, eligiendo únicamente artículos de investigación en dichas bases de datos.

En la búsqueda inicial se identificaron un total de 2285 artículos en las bases de datos definidas, de los cuales se excluyeron 88 por encontrarse duplicidad, además, se eliminaron 1860 artículos ya que estos no cumplían con los criterios de inclusión determinados, resultando en un total de 337 artículos. De los cuales quedaron 182 en Scopus y 117 en IEEEExplore y 38 en ResearchGate, para los cuales se realizó un análisis por el título y por el resumen priorizando que se tenga relación con el tema de investigación, quedando al final 71 artículos en Scopus, 17 en IEEEExplore y 16 en ResearchGate. Finalmente se realiza un estudio considerando los textos completos y evaluando su relación con el tema de investigación, con ello se excluyeron 35 artículos resultando en un total de 69 artículos. Todo el proceso descrito se encuentra representado en la Figura 1. Además, como parte de la metodología, debido a los criterios definidos y al acceso limitado a artículos de paga, se señala que podría existir un sesgo al momento de presentar los resultados, debido a temas financieros solo se tomaron en consideración artículos de acceso gratuito, además de las limitaciones de tiempo e idioma que se determinaron a la investigación.

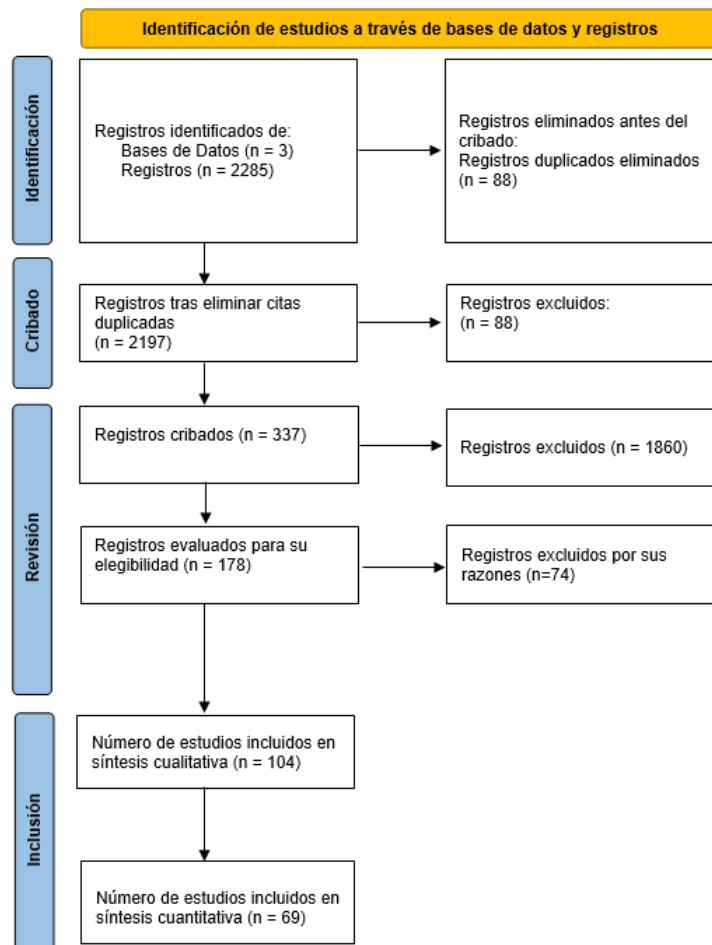


Figura 1. Diagrama de búsqueda según metodología PRISMA. Fuente: elaboración propia.

A partir de la relación de todos los artículos que fueron elegidos para la investigación, se desarrollaron una serie de gráficas que buscan ilustrar las características de los artículos que fueron seleccionados. En la Figura 2 muestra el número de artículos seleccionados por año de publicación. Puede observarse que 2021 es el año con mayor número de publicaciones, con un total de 26 artículos, seguido de 2022, que cuenta con 15 artículos. Esta información muestra la tendencia de publicación durante estos años.

El gráfico también incluye la distribución de estos artículos en los cuartiles de revistas científicas presentados en la Figura 3. Utilizando la clasificación realizada en el sitio web de Scimago, cada revista se clasificó en los cuartiles desde Q1 hasta Q4. Los resultados muestran que 33 artículos se publicaron en revistas Q1, 19 en journals de categoría Q2, 13 en journals de categoría Q3 y finalmente 4 en journals de categoría Q4. Esta información proporciona más información sobre la calidad y el impacto de las fuentes de publicación.




Figura 2. Cantidad de artículos publicados cada año en el periodo seleccionado y clasificado por los cuartiles de la revista. Fuente: elaboración propia.

La Figura 3 muestra los participantes por país, se identifica que el mayor número de investigadores provienen de China, con un total de 36 investigadores dedicados al campo de estudio, seguido por la India con un total de 5 y por Estados Unidos y Reino Unido con un total de 4.

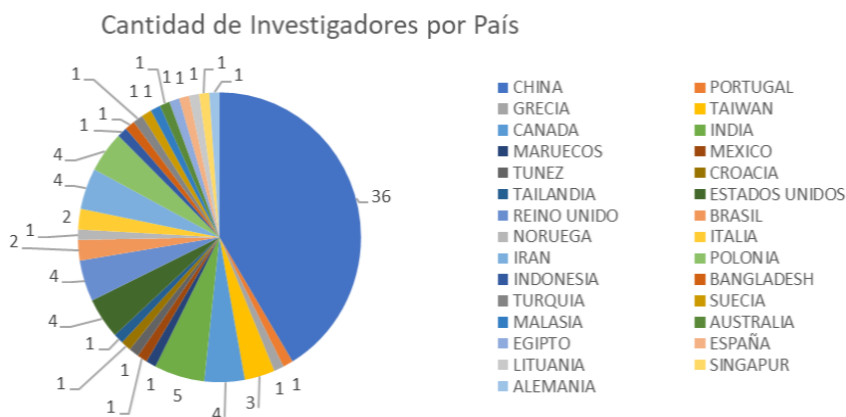


Figura 3. Autores clasificados por país. Fuente: elaboración propia.

Para el desarrollo de la Tabla 3, se realizó un conteo del total de citaciones de cada artículo, de los cuales en la tabla se clasificaron los 15 artículos con mayor número de citaciones, el cual demuestra que dichos artículos son los que resaltados en el campo de investigación que se está desarrollando.

Tabla 3. Top 15 de artículos por número de citaciones. Fuente: elaboración propia.

Referencia	Título	Citaciones
[22]	Forecasting SMEs' credit risk in supply chain finance with an enhanced hybrid ensemble machine learning approach	111
[23]	Application of new deep genetic cascade ensemble of SVM classifiers to predict the Australian credit scoring	95
[2]	Predicting mortgage default using convolutional neural networks	67
[24]	Enterprise credit risk evaluation based on neural network algorithm	48
[7]	A dynamic credit risk assessment model with data mining techniques: evidence from Iranian banks	43
[25]	Loan evaluation in P2P lending based on Random Forest optimized by genetic algorithm with profit score	41
[26]	SecureBoost: A Lossless Federated Learning Framework	40
[27]	Credit risk modeling using Bayesian network with a latent variable	35
[28]	Multi-view ensemble learning based on distance-to-model and adaptive clustering for imbalanced credit risk assessment in P2P lending	33
[10]	Big data analytics on enterprise credit risk evaluation of e-Business platform	32
[29]	A novel classifier ensemble approach for financial distress prediction	31
[30]	Automatic feature weighting for improving financial Decision Support Systems	22
[31]	Type-1 OWA Unbalanced Fuzzy Linguistic Aggregation Methodology: Application to Eurobonds Credit Risk Evaluation	22
[32]	An economic order quantity model under two-level partial trade credit for time varying deteriorating items	21
[6]	Utilizing historical data for corporate credit rating assessment	19
Total		660

La Figura 4 muestra los países en los cuales los artículos seleccionados fueron publicados. Se determinó que 33 de los artículos seleccionados fueron publicados en China, seguido por la India con 5 publicaciones.

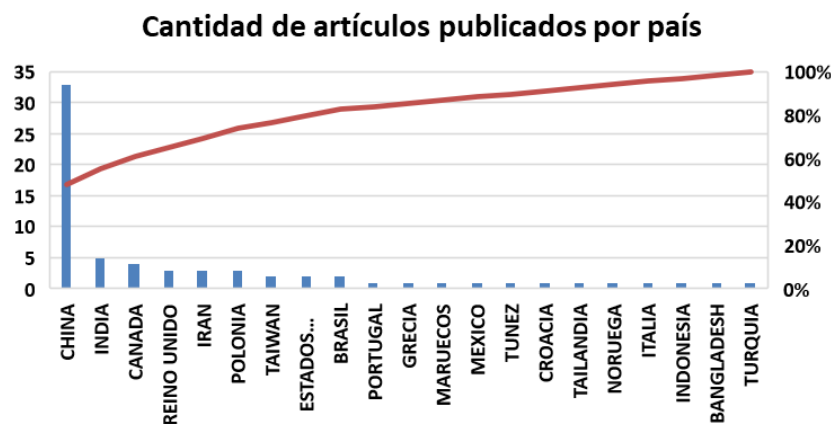


Figura 4. Cantidad de artículos publicados por país. Fuente: elaboración propia.

En la Tabla 4 se observa todas las palabras claves rescatadas de los artículos científicos estudiados. Estas palabras se agruparon en: tecnologías, cadena de suministros y procesos financieros. En el primer grupo se encontraron un total de 32 palabras clave relacionadas a las tecnologías usadas para la implementación de sistemas de riesgo crediticio, además, 22 palabras clave hacen referencia a procesos financieros relacionados a la evaluación de riesgo crediticio.

Tabla 4. Agrupación de palabras clave. Fuente: elaboración propia.

Grupo temático	Palabras clave
Tecnologías	Machine learning, fuzzy random forest, Genetic algorithm, logistic regression, python web framework2, Predictive intelligence, Deep multiple kernel classifier, Deep learning, Optimal model, Data mining, EM algorithm, Deep neural network, Mixture model, Z-Score Model, Internet of Things, RS-MultiBoosting, improved neural network, Random Forest, explainable algorithms, Deep forest, fuzzy clustering, Artificial Neural Networks, random forest, support vector machine, Firefly algorithm, SAW Method, Oriented Fuzzy Number, artificial intelligence, Machine learning algorithms, Prediction algorithms, XGBoost, CatBoost algorithm, Data mining, EM algorithm, Deep neural network, Mixture model, Z-Score Model, Internet of Things, RS-MultiBoosting, improved neural network, Random Forest, explainable algorithms.
Gerente de cadena de suministro	Supply chain management, supply chain finance, supply chain financing.
Procesos financieros	Credit risk scoring, Credit risk, Credit scoring, Bankruptcy prediction, Banknote authentication, Credit scoring, Optimal model, e-Business, Credit risk assessment, Intelligent Manufacturing, Risk analysis, P2P lending, Peer-to-peer lending, Mortgage default model, financial credit evaluation assessment, Internet finance, Federated Learning, systemic risk, soft information, Credit scoring model, feature selection, Feature selection.

Además de los pasos mencionados anteriormente y siguiendo los pasos de la metodología PRISMA, para el desarrollo de la revisión se determinó necesario realizar la extracción de datos, una vez que se seleccionaron los estudios relevantes, se procedió a la extracción de datos clave de cada artículo. Esto incluyó información relevante sobre los métodos utilizados, los resultados obtenidos y cualquier otra variable relevante para los objetivos de la revisión. La extracción de datos se realizó de manera sistemática y siguiendo un protocolo predefinido. Posteriormente, se llevó a cabo la síntesis de resultados. Los datos extraídos se sometieron a un proceso de síntesis para identificar patrones, tendencias y conclusiones clave en la literatura revisada. Esto permitió abordar los objetivos de investigación y responder a las preguntas planteadas de manera efectiva.

En paralelo, se realizó la evaluación de la calidad de los estudios. La metodología PRISMA promueve la evaluación crítica de la calidad metodológica de los estudios incluidos. Esta evaluación implica considerar factores como el diseño del estudio, el tamaño de la muestra, la validez de los resultados y la presencia de posibles sesgos. La calidad de los estudios seleccionados se tuvo en cuenta al interpretar los resultados. Cuando los estudios seleccionados presentaron resultados comparables y suficientemente homogéneos, se procedió al metaanálisis, que permitió combinar los datos y obtener estimaciones globales de los efectos. Esto contribuyó a una evaluación más precisa de la evidencia disponible. Finalmente, se llevó a cabo una evaluación continua de la heterogeneidad y el sesgo en los estudios incluidos. Esta evaluación constante permitió identificar posibles fuentes de heterogeneidad y sesgo a medida que se avanzaba en la revisión, lo que contribuyó a una interpretación más precisa de los resultados.

3. RESULTADOS Y DISCUSIÓN

3.1 Pregunta de investigación 1: ¿Qué soluciones son utilizados por los sistemas de evaluación de riesgo crediticio?

Los sistemas de evaluación de riesgo crediticio implementados en diferentes artículos científicos dan cuenta del uso de diversas soluciones informáticas, estas soluciones se dividen en tres tipos; los métodos, modelos y algoritmos que son aplicados para estos sistemas, los cuales cada investigador define en función al tema que desarrolla y al propósito de su investigación. La Tabla 5 muestra todas las soluciones identificadas en los artículos revisados.

Tabla 5. Soluciones utilizadas en la implementación de sistemas de evaluación de riesgo crediticio.
Fuente: elaboración propia.

Referencia	Soluciones	Descripción
[18]	SMOTE-PSO-LSSVM	Este método consiste en la aplicación de un sobre muestreo de minorías sintéticas combinando la técnica SMOTE con el algoritmo de búsqueda gravitacional de optimización de enjambre de partículas (PSO).
[33]	CNN Model	Es un modelo de red jerárquica multicapa que consiste en realizar varias transformaciones utilizando un banco de núcleos convolucionales. El procedimiento de convolución ayuda en la extracción de características valiosas de puntos de datos que están espacialmente conectados.
[34]	Deep Multiple Kernel Classifier	Este método es una versión optimizada de la estructura de Deep Learning, el cual se centra en el uso de múltiples núcleos de procesamiento en lugar de uno con la finalidad aumentar la riqueza de la representación de las características.
[35]	RB Genetic Algorithm	Este algoritmo consiste en la combinación del método de equilibrio aleatorio adaptativo (RB) y el algoritmo XGBoost para la construcción de un modelo de evaluación de riesgo de crédito.
[36], [37]	Algoritmo genético	En este trabajo se presenta un sistema de aprendizaje adaptativo de filtrado secuencial para la modelización del riesgo crediticio haciendo uso de algoritmos genéticos para los patrones de preseleccionados.
[10]	Algoritmo SMOTE	SMOTE consiste en una técnica de sobre muestreo donde las muestras sintéticas se generan para la clase minoritaria. Este algoritmo ayuda a superar el problema de sobreajuste planteado por el sobre muestreo aleatorio.
[38]	Algoritmo de optimización de enjambre de partículas de mutación dinámica	El algoritmo en este artículo fue diseñado para evitar el problema de las partículas que caen en un mínimo local en el proceso de optimización, se utiliza para optimizar los parámetros de SVM y la integración de AdaBoost como clasificador débil para construir un modelo integrado con buen rendimiento en muchos aspectos.
[2], [39]	Método de Red Neuronal Convolutacional	Este método consiste en una serie de redes que fueron creadas pensando en cómo funciona el cerebro, capaces de aprender en los diferentes niveles de abstracción.
[27]	Red bayesiana con una variable latente	Este modelo consiste en que mientras que la estructura de BN modela las relaciones probabilísticas entre los factores que conducen al pago de los créditos, la variable latente permite representar diferentes clases de distribuciones de probabilidad.
[40]	Modelo de Red Neuronal Profunda	El propósito principal de este método es recibir un conjunto de entradas, realizar cálculos progresivamente complejos en ellas y dar salida para resolver problemas del mundo real como la clasificación. Nos limitamos a alimentar las redes neuronales.

[41]	Algoritmo de Bosque Aleatorio	El algoritmo de bosque aleatorio ponderado se utiliza para clasificar los datos de riesgo de crédito financiero, construir el sistema de índice de evaluación y utilizar el proceso de jerarquía analítica para evaluar el nivel de riesgo de crédito financiero.
[22]	RS-MultiBoosting	El modelo consiste en incorporar dos enfoques clásicos de ML ensemble, el subespacio aleatorio (RS) y el MultiBoosting, para mejorar la precisión de la previsión del riesgo crediticio de las PYME. El resultado de la previsión muestra que el RS-MultiBoosting tiene un buen rendimiento cuando se trata de un tamaño de muestra pequeño.
[42]	AHP-LSTM	Este modelo consiste en incorporar el proceso de jerarquía analítica en el modelo de memoria a corto plazo. En primer lugar, se extrae la información característica y se establece la estructura del sistema de índices de evaluación del riesgo crediticio financiero. Los datos se introducen en la red neuronal AHP-LSTM, y los datos del índice se fusionan con el AHP para obtener el nivel de riesgo y servir como salida esperada de la red neuronal LSTM.
[43]	Algoritmo Bagging para Random Forest	El algoritmo Random Forest, es un ejemplo de ensamblados de Bagging. Consiste en entrenar una serie de árboles de decisión, para que luego voten el resultado por mayoría en clasificación u obtengan la media si es un problema de regresión.
[44]	Árbol de decisión de gradiente de múltiples capas (GBDT)	En este modelo se emplean los árboles de decisión potenciados por gradientes para optimizar el valor predictivo de un modelo a través de procesos de aprendizaje automático.
[28]	Método de aprendizaje multivista basado en la distancia al modelo y la agrupación adaptativa	En este método, se explora el aprendizaje multivista y un método de clustering adaptativo para producir un conjunto de diversos ensamblados constituidos por árboles de decisión de gradient boosting.
[45]	BPNN (Red neuronal artificial de retropropagación)	En este artículo aplica los métodos de BPNN para el diseño de un modelo de predicción de impagos de préstamos en la red, demostrando que dicho modelo basado en BPNN muestra un alto valor aplicativo y una alta tasa de predicción respecto a otros modelos.
[46]	ReG-Rules	Este modelo describe el marco general de un sistema de clasificación por conjuntos basado en reglas que consta de 5 etapas con varias operaciones: Generación de Diversidad, Inducción de Clasificadores Base, Selección de Modelos, Fusión de Reglas, Combinación y Predicción.
[47]	Árbol de decisión de gradiente aumentado multigrano (mg-GBDT)	El artículo desarrolla un escaneo multigrano para el aumento de la característica, que enriquece la característica de entrada de GBDT; el mecanismo de optimización paso a paso basado en GBDT asegura una baja desviación de la puntuación de crédito; además, el método propuesto hereda la buena interpretabilidad de la estructura basada en el árbol, que proporciona resultados de referencia intuitivos para los responsables políticos.
[48]	Modelo de máquina de vectores de apoyo conjunto	Las principales características de este enfoque incluyen que se propone un novedoso esquema de filtrado de ruidos que evita los ejemplos ruidosos basado en la agrupación difusa y el algoritmo de análisis de componentes principales para eliminar tanto el ruido de los atributos como el de las clases para lograr un conjunto limpio óptimo, y los clasificadores de la máquina de vectores de soporte, basados en el algoritmo mejorado de optimización de enjambre de partículas.
[8], [14]	Aprendizaje automático	Estos artículos presentan una comparación entre varios modelos basados en Machine Learning que se pueden aplicar al desarrollo de un sistema de evaluación de riesgo crediticio.

[6]	Redes neuronales artificiales paralelas (PANNs)	El modelo de PANNs propuesto consta de tres etapas: la primera consiste en crear los clasificadores de la red neuronal, la segunda, en integrar los múltiples clasificadores en una salida de conjunto, la tercera, en realizar el proceso de aprendizaje del modelo de PANNs.
[49]	Algoritmo de luciérnaga	Este artículo propone una mejora al algoritmo de la luciérnaga para resolver problemas de optimización y selección de características.
[5]	Algoritmo competitivo imperialista con clasificador fuzzy min-max modificado (ICA-MFMCN)	Este algoritmo fue diseñado para identificar un subconjunto óptimo de características y aumentar a través de la clasificación de precisión y escalabilidad a través de la evaluación del riesgo de crédito.
[50]	Red neuronal difusa	Este artículo desarrolla un sistema de evaluación de riesgo crediticio llamado SC-IR2FNN basado en los métodos de las redes neuronales difusas.
[7]	Sistema de inferencia difusa basado en una red adaptativa (ANFIS)	Este modelo consiste en implementar un sistema basado en redes adaptativas con la finalidad de diseñar un modelo de evaluación de riesgo crediticio adaptativo y que elimine por completo el juicio humano.
[51]	Máquina de vectores de apoyo (SVM)	El concepto de SVM es encontrar el hiperplano óptimo con el máximo margen para separar linealmente el conjunto de datos en dos clases.
[52]	Algoritmo CatBoost	Swindle implementa el algoritmo CatBoost para predecir los impagos de los préstamos junto con un módulo de verificación de documentos utilizando Tesseract y Camelot y también un módulo de préstamos personalizados, mitigando así el riesgo de los institutos financieros en la emisión de préstamos a los morosos y clientes no autorizados.

3.2 Pregunta de investigación 2: ¿Qué soluciones son las más eficientes para la implementación de un sistema de evaluación de riesgo crediticio?

Evaluando cada una de las soluciones identificadas en los artículos de investigación, se evaluó el nivel de eficiencia de cada una, la cual es determinada por el porcentaje de precisión de los sistemas desarrollados y las cuales son descritas por los autores. El nivel de eficiencia será medido por 3 criterios: poco eficiente, eficiente y muy eficiente, todo ello con la finalidad de terminar las mejores soluciones dentro de los trabajos analizados, en la Tabla 6 se muestran las soluciones clasificadas por el nivel de eficiencia.

Tabla 6. Soluciones más eficientes. Fuente: elaboración propia.

Referencia	Soluciones	Nivel de eficiencia	Ventajas/desventajas	Condiciones
[18]	SMOTE-PSO-LSSVM	Muy eficiente	Aumenta la precisión al abordar el desequilibrio de datos, aunque puede ser computacionalmente costoso.	Ideal cuando se cuenta con conjuntos de datos desequilibrados.
[33]	CNN Model	Muy eficiente	Efectivo en la extracción de características complejas de datos, pero requiere una gran cantidad de datos para entrenamiento.	Recomendado cuando se cuenta con grandes cantidades de datos.
[34]	Deep Multiple Kernel Classifier	Eficiente	Capaz de manejar características no lineales. Puede requerir ajustes de hiperparámetros sensibles.	Ideal cuando las relaciones entre las características son no lineales.
[35]	RB-XGBoost algorithm	Eficiente	Buen equilibrio entre velocidad y rendimiento, pero puede ser susceptible al sobreajuste.	Adecuado para conjuntos de datos de tamaño mediano a grande con características mixtas.
[36]	Algoritmo genético	Eficiente	Capaz de encontrar soluciones globales, aunque puede resultar en un costo computacional mayor.	Útil cuando se necesita encontrar soluciones óptimas en espacios de búsqueda complejos.

[10]	Algoritmo SMOTE	Muy eficiente	Mejora el rendimiento en clases minoritarias, pero puede generar muestras sintéticas que se superponen con las existentes.	Recomendado cuando se trata con desequilibrio de clases.
[38]	Algoritmo de optimización de enjambre de partículas de mutación dinámica (AdaBoost-DPSO-SVM)	Muy eficiente	Combina múltiples algoritmos para mejorar la precisión, pero es computacionalmente exigente.	Adecuado cuando se busca un alto rendimiento y se pueden utilizar múltiples algoritmos.
[39]	Método de Red Neuronal Convolutiva (CNN)	Muy eficiente	Efectivo en la extracción de características complejas de datos, pero requiere una gran cantidad de datos para entrenamiento.	Recomendado cuando se cuenta con grandes cantidades de datos.
[27]	Bayesian Network (BN) with a latent variable	Muy eficiente	Maneja la incertidumbre de manera efectiva, aunque su complejidad operativa es mayor.	Ideal cuando se tiene información probabilística y se desea modelar la incertidumbre.
[40]	Modelo de Red Neuronal Profunda	Eficiente	Capaz de aprender representaciones complejas de datos, pero se requiere de mayores datos de entrenamiento. Brinda rapidez en la clasificación de patrones, aunque pierde eficiencia ante mayores parámetros.	Adecuado para problemas con datos complejos y dispersos. Útil cuando se necesita una clasificación rápida y con pocos parámetros.
[24]	PNN	Eficiente		Recomendado si se desconoce la estructura de los datos o el volumen de los mismos.
[41]	Algoritmo de Bosque Aleatorio	Muy eficiente	Efectivo frente a datos ruidosos y características poco relacionadas.	Útil para la clasificación multiclase en conjuntos de datos limpios.
[22]	RS-MultiBoosting	Eficiente	Eficiente en la clasificación multiclase, aunque presenta baja precisión frente a datos ruidosos.	Adecuado cuando se deben considerar múltiples criterios en la toma de decisiones.
[42]	AHP-LSTM	Muy eficiente	Integra análisis multicriterio en el proceso de aprendizaje, lo que involucra una mayor complejidad.	
[37]	Random Forest optimized by genetic algorithm with profit score	Eficiente	Ofrece una mayor optimización, aunque con ello una mayor complejidad.	Es ideal cuando se busca maximizar los resultados de la clasificación.
[43]	Algoritmo Bagging para Random Forest	Muy eficiente	Permite reducir la varianza y el sobreajuste, aunque puede no funcionar tan bien en datos altamente desequilibrados.	Resulta adecuado para problemas de clasificación con alta varianza.
[44]	Árbol de decisión de gradiente de múltiples capas (GBDT)	Eficiente	Mayor capacidad de manejar características de diferentes tipos, aunque ello requiere un mayor ajuste de parámetros.	Ideal cuando se tienen características mixtas en los datos a procesar.
[28]	Método de aprendizaje multivista basado en la distancia al modelo y la agrupación adaptativa (DM-ACME)	Eficiente	Eficiente en el procesamiento de datos multivista., aunque requiere una cuidadosa selección de características.	Adecuado cuando se trabaja con múltiples vistas de datos.
[45]	Back Propagation Neural Network (BPNN)	Muy eficiente	Es adecuado para problemas de regresión y clasificación, pero decae con conjuntos de datos grandes.	Es útil cuando el volumen de los datos a procesar es limitado, puesto que en volúmenes grandes la

				eficiencia decae progresivamente.
[2]	Método de Red Neuronal Convolutacional (CNN)	Muy eficiente	Adecuado para problemas de reglas, pero puede no ser tan preciso como modelos complejos.	Recomendado cuando se cuenta con grandes cantidades de datos.
[46]	ReG-Rules	Muy eficiente	Adecuado para problemas de reglas, pero puede no ser tan preciso como modelos complejos.	Ideal cuando se necesita interpretabilidad y reglas claras.
[47]	Árbol de decisión de gradiente aumentado multigrano (mg-GBDT)	Poco eficiente	Funciona bien en problemas con múltiples niveles de granularidad, pero es lento en comparación con otros algoritmos.	Útil cuando se necesita modelar la granularidad en los datos en modelos de prueba.
[53]	Modelo EN-AdaPSVM	Muy eficiente	Combina múltiples algoritmos para mejorar el rendimiento, pero ello conlleva un mayor consumo computacional.	Adecuado cuando se busca un alto rendimiento y se pueden utilizar múltiples algoritmos.
[8]	Machine Learning	Eficiente	Posee mayor flexibilidad dependiendo el algoritmo empleado, aunque requiere de un mayor número de ajustes.	Ideal cuando se necesite una clasificación final para diferentes tipos de datos.
[6]	Redes neuronales artificiales paralelas (PANNs)	Eficiente	Aprovecha el paralelismo para el procesamiento eficiente de datos, pero ello aumenta el nivel de complejidad del algoritmo.	Útil cuando se busca una mejora en la velocidad de procesamiento para volúmenes de datos específicos.
[49]	Firefly algorithm	Eficiente	Permite una optimización global de la implementación, pero puede requerir ajuste de parámetros.	Adecuado cuando se necesita encontrar soluciones óptimas en espacios de búsqueda complejos.
[5]	Algoritmo competitivo imperialista con clasificador fuzzy min-max modificado (ICA-MFMCN)	Eficiente	Capaz de manejar la incertidumbre y una clasificación con mayor número de parámetros.	Recomendado cuando se necesita manejar la incertidumbre en la clasificación crediticia.
[50]	Fuzzy Neural Network	Eficiente	Adecuado para problemas con una mayor incertidumbre y para datos que aun no fueron normalizados.	Útil cuando se necesite modelar relaciones entre los datos para determinar características en común.
[7]	Sistema de inferencia difusa basado en una red adaptativa (ANFIS)	Eficiente	Combina la lógica difusa y el aprendizaje automático permitiendo un mejor resultado, pero puede requerir ajuste de parámetros.	Adecuado se necesita determinar relaciones entre características y se dispone de datos de entrenamiento.
[51]	Máquina de vectores de apoyo (SVM)	Muy eficiente	Efectivo en la separación de clases lineales y no lineales, pero depende mucho de la elección del kernel.	Recomendado para problemas de clasificación con alto rendimiento.
[14]	Machine Learning	Muy eficiente	Posee mayor flexibilidad dependiendo el algoritmo empleado, aunque requiere de un mayor número de ajustes.	Recomendado cuando se necesita una solución general para diferentes tipos de datos.
[1]	Modelo PCA-GA-FS	Muy eficiente	Integra técnicas de selección de características y reducción de dimensionalidad, aunque puede requerir ajuste de parámetros.	Útil cuando se busca una representación más compacta de los datos.
[52]	Algoritmo CatBoost	Eficiente	Optimizado para conjuntos de datos categóricos, aunque puede ser sensible a la elección de hiperparámetros.	Adecuado para conjuntos de datos con muchas características categóricas.

3.3 Pregunta de investigación 3: ¿Qué modelos de riesgo crediticio utilizan las entidades bancarias?

Asimismo, en las investigaciones revisadas se determinan modelos financieros para la evaluación de riesgo crediticio. Un modelo de evaluación crediticia permite la ponderación de variables cualitativas y cuantitativas que permiten la recopilación de información para evaluar la calidad crediticia de un cliente [54], estos modelos permiten a las entidades financieras medir con base a sus propias variables y especificaciones el nivel de riesgo que representa el otorgamiento de crédito financiero a un solicitante. En la Tabla 7 se muestra los modelos identificados en la revisión.

Luego de revisado los artículos de investigación, se determinaron un total de 10 modelos financieros para la evaluación de riesgo crediticio, los cuales permiten la definición de las variables necesarias para la evaluación y se van adaptando, dependiendo de los requerimientos necesarios. Muchos de estos modelos están incorporando como factor de evaluación las características demográficas de los individuos a fin de mejorar la precisión en las evaluaciones.

Table 7. Tabla de modelos financieros para la evaluación de riesgo crediticio. Fuente: elaboración propia.

Referencia	Modelos	Observación
[13]	Modelo completo para la calificación del riesgo crediticio.	El objetivo del modelo completo para la calificación del riesgo crediticio es apoyar a los responsables de la toma de decisiones mediante la recopilación de información de datos y la aplicación de estadísticas, inteligencia artificial y otras técnicas.
[32]	Modelo económico de cantidad de pedido bajo crédito comercial parcial de dos niveles	En este artículo, se propuso un modelo de crédito de dos niveles para elementos deteriorados que varían en el tiempo. Debido a las condiciones de concesión del crédito, aplicamos el riesgo de impago. Además, suponemos que el proveedor/minorista ofrece el crédito comercial parcial al minorista/cliente.
[17]	Modelo óptimo de eliminación hacia atrás y el método de regresión hacia delante	El objetivo de este trabajo es verificar si existe una relación entre el riesgo crediticio, principal amenaza para los bancos, y las características demográficas, maritales, culturales y socioeconómicas de una muestra de 40 solicitantes de crédito, utilizando el modelo óptimo de eliminación hacia atrás y el método de regresión hacia adelante.
[55]	Método de ajuste de la valoración del crédito	Según el requisito de medición del riesgo de crédito de contraparte del Acuerdo de Basilea, el activo ponderado por el riesgo de crédito de contraparte es la suma del activo ponderado por el riesgo de impago del riesgo de crédito de contraparte y el activo ponderado por el ajuste de valoración del crédito.
[56]	Modelos aditivos generalizados	Describe la implementación mediante métodos, los aplicamos a una gran cartera de cuentas de tarjetas de crédito y mostramos cómo los GAM pueden utilizarse para mejorar no sólo la aplicación, los componentes conductuales y macroeconómicos de los modelos de supervivencia para datos de riesgo de crédito a nivel de cuenta individual, sino también la precisión de las predicciones.
[12]	Modelo de regresión logística	De acuerdo con la definición de si la variable dependiente prestatario incumple en la regresión logística, el prestatario se divide en incumple y no incumple. Entre ellos, los prestatarios no morosos se marcan como 0, y los morosos como 1.
[11]	Modelo de regresión espacial binaria	En este trabajo se aplicó un modelo de regresión espacial binaria para medir los efectos de contagio derivados de las quiebras empresariales. Para derivar las medidas de interconexión, utilizamos las estadísticas del World Input-Output Trade (WIOT) entre sectores económicos.

[19]	Cadena de suministro B2B	Basado en la plataforma de comercio electrónico B2B, se utiliza para las transacciones en línea y las transacciones entre empresas y compañías. Información, integrando la logística, el flujo de negocios, el flujo de información y el flujo de capital para el análisis y el procesamiento de datos.
[31]	Type-1 OWA Unbalanced Fuzzy Linguistic Aggregation Methodology	Se utiliza la metodología del operador T1OWA para evaluar la solvencia de los bonos europeos en función de las calificaciones de riesgo crediticio reales de los estados miembros individuales de la eurozona modelados como etiquetas lingüísticas difusas desequilibradas.
[57]	Modelo de Riesgo Moral	El riesgo moral es un problema causado principalmente por la asimetría de información ex-post en un contrato, especialmente después de la firma del mismo. Este problema surge debido a la incapacidad de los agentes de poder observar las acciones de otros agentes.

3.4 Pregunta de investigación 4: ¿Qué problemas o limitaciones pueden surgir al implementar un sistema de evaluación de riesgo crediticio?

Finalmente, de los artículos revisados se determinaron 3 limitaciones o problemas que surgen a la otra de realizar una implementación para un sistema de evaluación de riesgo crediticio, una limitación o problema es un factor que puede influir en el desarrollo de una investigación generando obstáculos al investigador. En la Tabla 8 se definen los problemas y limitaciones presentes en los artículos de investigación.

Tabla 8. Limitaciones y problemas. Fuente: elaboración propia.

Referencia	Limitación/problema	Descripción
[58]-[59]	Aplicación continua del modelo de regresión logística	Esta limitación se presenta al momento de la evaluación y presentación de los resultados del sistema, pues si bien es evidente que en el ámbito de la evaluación del riesgo crediticio se ha estudiado un gran número de modelos no lineales diferentes en el ámbito de la evaluación del riesgo crediticio, los requisitos normativos sobre la explicabilidad de los resultados del modelo son una de las principales razones por las que la regresión logística sigue siendo el estándar del sector.
[44], [47]	Teorema "no free lunch"	Este teorema plantea una limitación al momento de elegir los algoritmos que serán usados en la implementación, ya que la escala y el número de variables de los conjuntos de datos de crédito varían bastante, los apéndices de calificación crediticia de base individual no pueden hacer frente a todos los problemas complejos en la calificación crediticia.
[28]	Rendimiento	Cuando se trata de problemas de clasificación muy desequilibrados, la alta precisión absoluta no es deseable. Lo que perseguimos es un buen rendimiento de predicción global con una capacidad de generalización satisfactoria.

Se concluye que si bien, las limitaciones o problemas descritos no afectan en gran medida a la implementación de los sistemas de evaluación de riesgo crediticio, la persistencia de la regresión logística como estándar en el sector, debido a los requisitos normativos de explicabilidad, subraya la importancia de equilibrar la innovación con la transparencia en la toma de decisiones crediticias. Además, el desafío planteado por el teorema 'no free lunch' subraya la necesidad de adaptar los algoritmos a las variaciones en los datos crediticios, reconociendo que no existe un enfoque único que se ajuste a todos los casos. Además, la gestión del rendimiento en situaciones de clasificación desequilibrada subraya la importancia

de no centrarse únicamente en la alta precisión absoluta, sino en lograr un buen rendimiento global y una capacidad de generalización.

Es por ello que, aunque las limitaciones identificadas no obstaculizan de manera significativa la implementación de los sistemas de evaluación de riesgo crediticio, subrayan la importancia de abordar estratégicamente estos desafíos para mejorar aún más la calidad y la eficacia de las evaluaciones crediticias en un entorno en constante evolución.

Una vez culminada la revisión de los artículos seleccionados, se identificaron un total de 31 soluciones utilizadas en los diferentes artículos revisados, de los cuales se concluye que los algoritmos y técnicas basadas en inteligencia artificial están presentes en la mayoría de implementaciones realizadas en los artículos de investigación, siendo las redes neuronales una de las soluciones más utilizadas esto debido a que muchos de los investigadores afirman que permite un procesamiento de datos eficiente y puede adaptarse y combinarse con diversos algoritmos a fin de mejorar el rendimiento, de igual manera se evidencia el creciente uso de la técnica de Árbol de Decisión, la cual está siendo aplicada a investigaciones más recientes debido a su capacidad de predicción basada en características. Si bien estas soluciones describen buenos resultados en las implementaciones, muchos de estos son validados y comprobados con bases de datos simuladas a partir de la información recopilada por diversos bancos alrededor del mundo, los cuales, si bien demuestran la funcionalidad del sistema, no asemejan los resultados a la realidad de algunas organizaciones.

Luego de analizado los artículos de investigación, se encontró que de un total de 31 artículos, el 48 % de ellos se clasificó como “Muy eficiente” dado que el nivel de precisión descrito en los resultados de las investigaciones era superior al 90 %, dentro de las cuales las técnicas de inteligencia artificial están dentro de las que mostraron un gran porcentaje de eficiencia, si bien en los trabajos se destacan los buenos resultados de los sistemas que se implementan debido a su alto nivel de precisión, cabe la posibilidad de que algunos de estos artículos presenten resultados sesgados debido a que algunas investigaciones mostraban resultados del 100 %, lo cual es algo poco probable.

Además, para la implementación de estos sistemas es necesario contar con modelos que determinen las variables que se requieren evaluar, pero la mayoría de los trabajos revisados describe pocas soluciones donde se muestra la lógica de la evaluación crediticia.

Finalmente, en los artículos revisados se identificaron un total de 3 limitaciones, las cuales describen los puntos que se deben de considerar referentes a diversos aspectos de la implementación, sin embargo, fueron 3 los trabajos que registran y describen las limitaciones o problemas que puedan surgir en la implementación.

4. CONCLUSIONES

Culminado el trabajo, se concluye que actualmente el desarrollo de los sistemas de evaluación de riesgo crediticio se encuentra a nivel mundial principalmente en los países de China, India y Estados Unidos, lo cual evidencia un gran interés de estos países por innovar constantemente en la implementación de estos sistemas.

De igual manera, relacionado con los métodos, modelos y algoritmos se concluye que, si bien muestran un gran aporte al desarrollo de estos sistemas, es necesario analizar la funcionalidad de estos sistemas con bases de datos reales y no simuladas, a fin de garantizar resultados que se adecuen a la realidad de muchas organizaciones, de entre los métodos, modelos y algoritmos analizados se destaca el uso de la Inteligencia artificial en la mayoría de los trabajos, destacando las técnicas de Redes Neuronales y Random Forest presentes en

la mayoría de los trabajos y los cuales son combinados con diversos algoritmos a fin de garantizar resultados específicos según se requiera en la implementación.

Además, se concluye que todas las soluciones analizadas muestran una eficiencia sobresaliente con las particularidades que posee cada una. Dentro de los resultados se resalta la eficiencia principalmente de las técnicas relacionadas con redes neuronales, en particular las que emplean las redes neuronales profundas o convolucionales, debido a su gran capacidad de predicción de resultados basados en el reconocimiento de características, presentando una eficiencia superior a la media en el nivel de precisión de los sistemas implementados. Estas redes tienen la capacidad de identificar y analizar minuciosamente las características y patrones de los datos, lo que resulta en pronósticos precisos y confiables. De igual manera, los algoritmos basados en Random Forest presentaron una destacada capacidad predictiva en la evaluación de riesgo crediticio. Estos algoritmos aprovechan la diversidad y el poder de predicción de una colección de árboles individuales para ofrecer pronósticos confiables y consistentes, lo que resulta en modelos más robustos y generalizables; aunque esto implica una posible deficiencia ante grandes volúmenes de datos o variables, lo que puede aumentar la complejidad computacional y requerir recursos significativos de procesamiento y almacenamiento. A pesar de esta destacada eficacia de las mencionadas tecnologías, es importante señalar que la mayoría de las otras implementaciones también presentaron resultados satisfactorios. Sin embargo, en algunos casos, se observaron márgenes de imprecisión, lo que destaca la importancia continua de la mejora y el refinamiento de los métodos utilizados.

Por otro lado, para el desarrollo de sistemas de evaluación es importante conocer la lógica de las variables que son empleadas para la implementación de las evaluaciones, lo cual no es descrito por muchos trabajos, por ello, para futuras investigaciones se recomienda que se enfoquen en áreas específicas que pueden mejorar aún más el desarrollo de los sistemas de evaluación de riesgo crediticio. Estos trabajos podrían abordar de manera más exhaustiva áreas como la optimización de algoritmos de inteligencia artificial, con un enfoque en alcanzar una precisión aún mayor en la evaluación del riesgo crediticio. También, se recomienda llevar a cabo investigaciones adicionales que utilicen datos del mundo real en lugar de simulaciones, lo que ayudaría a identificar y abordar posibles desafíos y limitaciones en la implementación práctica. La inclusión de factores demográficos en la evaluación del riesgo crediticio se presenta como una oportunidad clave para futuras investigaciones, explorando cómo integrar de manera efectiva estos factores y cómo adaptar los modelos a diferentes poblaciones. Por último, es esencial considerar cómo los resultados de la investigación actual y futura pueden impactar la industria financiera y la toma de decisiones relacionadas con el riesgo crediticio, con un enfoque en cómo estas investigaciones pueden beneficiar a las organizaciones financieras y a los consumidores en general.

5. AGRADECIMIENTOS Y FINANCIACIÓN

Esta investigación no cuenta con apoyo económico de ningún organismo ni de institución pública o privada.

CONFLICTOS DE INTERÉS

Los autores declaran que no existe ningún conflicto de interés.

CONTRIBUCIÓN DE LOS AUTORES

Frank Edward Tadeo Espinoza: redacción, desarrollo metodológico, resultados y conclusiones.

Marco Antonio Coral Ygnacio: revisión de la redacción y estructuración del artículo.

6. REFERENCIAS

- [1] S. R. Lenka, S. K. Bisoy, R. Priyadarshini, J. Hota, and R. K. Barik, "An effective credit scoring model implementation by optimal feature selection scheme," *2021 Int. Conf. Emerg. Smart Comput. Informatics (ESCI)*, Pune, India, 2021, pp. 106–109. <https://doi.org/10.1109/ESCI50559.2021.9396911>
- [2] H. Kvamme, N. Sellereite, K. Aas, and S. Sjursen, "Predicting mortgage default using convolutional neural networks," *Expert Syst. Appl.*, vol. 102, pp. 207–217, Jul. 2018. <https://doi.org/10.1016/j.eswa.2018.02.029>
- [3] S. Wen, B. Zeng, W. Liao, P. Wei, and Z. Pan, "Research and Design of Credit Risk Assessment System Based on Big Data and Machine Learning," *2021 IEEE 6th Int. Conf. Big Data Analytics (ICBDA)*, Xiamen, China, 2021, pp. 9–13. <https://doi.org/10.1109/ICBDA51983.2021.9403128>
- [4] F. Wu, X. Su, Y. S. Ock, and Z. Wang, "Personal credit risk evaluation model of P2P online lending based on AHP," *Symmetry*, vol. 13, no. 1, p. 83, Jan. 2021. <https://doi.org/10.3390/sym13010083>
- [5] J. Nourmohammadi-Khiarak, M.-R. Feizi-Derakhshi, F. Razeghi, S. Mazaheri, Y. Zamani-Harghalani, and R. Moosavi-Tayebi, "New hybrid method for feature selection and classification using meta-heuristic algorithm in credit risk assessment," *Iran J. Comput. Sci.*, vol. 3, pp. 1–11, Jun. 2020. <https://doi.org/10.1007/s42044-019-00038-x>
- [6] M. Wang and H. Ku, "Utilizing historical data for corporate credit rating assessment," *Expert Syst. Appl.*, vol. 165, p. 113925, Mar. 2021. <https://doi.org/10.1016/j.eswa.2020.113925>
- [7] S. Moradi and F. Mokhtab Rafiei, "A dynamic credit risk assessment model with data mining techniques: evidence from Iranian banks," *Financ. Innov.*, vol. 5, no. 15, Mar. 2019. <https://doi.org/10.1186/s40854-019-0121-9>
- [8] A. Fenerich *et al.*, "Use of machine learning techniques in bank credit risk analysis," *Revista Internacional de Métodos Numéricos para Cálculo y Diseño en Ingeniería*, vol. 36, no. 3, p. 40, Sep. 2020. <https://doi.org/10.23967/J.RIMNI.2020.08.003>
- [9] A. Wójcicka-Wójtowicz, A. Lyczkowska-Hanckowiak, and K. Maciej Piasecki, "Credit Risk Assessment by Ordered Fuzzy Numbers," *SSRN Electron. J.*, Nov. 2019. <https://doi.org/10.2139/ssrn.3479218>
- [10] A. Niu, B. Cai, and S. Cai, "Big Data Analytics for Complex Credit Risk Assessment of Network Lending Based on SMOTE Algorithm," *Complexity*, vol. 2020, p. 8563030, Sep. 2020. <https://doi.org/10.1155/2020/8563030>
- [11] A. Agosto, P. Giudici, and T. Leach, "Spatial Regression Models to Improve P2P Credit Risk Management," *Front. Artif. Intell.*, vol. 2, May. 2019. <https://doi.org/10.3389/frai.2019.00006>
- [12] Y. Cao, "Internet financial supervision based on machine learning and improved neural network," *J. Intell. Fuzzy Syst.*, vol. 40, no. 4, pp. 7297–7308, Apr. 2021. <https://doi.org/10.3233/JIFS-189555>
- [13] C. Luo, "A comprehensive decision support approach for credit scoring," *Ind. Manag. Data Syst.*, vol. 120, no. 2, pp. 280–290, Oct. 2019. <https://doi.org/10.1108/IMDS-03-2019-0182>
- [14] A. A. Turjo, Y. Rahman, S. M. M. Karim, T. H. Biswas, I. Dewan, and M. I. Hossain, "CRAM: A Credit Risk Assessment Model by Analyzing Different Machine Learning Algorithms," *4th International Conference on Information and Communications Technology*, Yogyakarta, Indonesia, 2021 pp. 125–130. <https://doi.org/10.1109/ICOIACT53268.2021.9563995>
- [15] A. Wójcicka-Wójtowicz and K. Piasecki, "Application of the oriented fuzzy numbers in credit risk assessment," *Mathematics*, vol. 9, no. 5, p. 535, Mar. 2021. <https://doi.org/10.3390/math9050535>
- [16] C. Yung-Chia, C. Kuei-Hu, and H. Yi-Hsuan, "A novel fuzzy credit risk assessment decision support system based on the python web framework," *J. Ind. Prod. Eng.*, vol. 37, no. 5, pp. 229–244, Jun. 2020. <https://doi.org/10.1080/21681015.2020.1772385>
- [17] S. Haloui and A. El Moudeden, "An optimal prediction model's credit risk: The implementation of the backward elimination and forward regression method," *International Journal of Advanced Computer Science and Applications*, vol. 11, no. 2, p. 9549868, 2020. <https://doi.org/10.14569/ijacsa.2020.0110259>
- [18] H. Xie and Y. Shi, "A Big Data Technique for Internet Financial Risk Control," *Mob. Inf. Syst.*, vol. 2022, Jul. 2022. <https://doi.org/10.1155/2022/9549868>
- [19] L. Cheng-yong, D. Tian-yu, and M. Ling-xing, "The Prevention of Financial Legal Risks of B2B E-commerce Supply Chain," *Wirel. Commun. Mob. Comput.*, vol. 2022, p. 6154011, Jan. 2022.

- <https://doi.org/10.1155/2022/6154011>
- [20] Y. Li, “Credit risk prediction based on machine learning methods,” *14th Int. Conf. Comput. Sci. Education*. Toronto, Canada, 2019 pp. 1011–1013. <https://doi.org/10.1109/ICCSE.2019.8845444>
- [21] A. Liberati *et al.*, The PRISMA statement for reporting systematic reviews and meta-analyses of studies that evaluate health care interventions: explanation and elaboration, *Journal of Clinical Epidemiology*, vol. 62, no. 10, pp. e1–e34 Oct. 2009. <https://doi.org/10.1016/j.jclinepi.2009.06.006>
- [22] Y. Zhu, L. Zhou, C. Xie, W. Gang-Jin, and N. Truong. V, “Forecasting SMEs’ credit risk in supply chain finance with an enhanced hybrid ensemble machine learning approach,” *Int. J. Prod. Econ.*, vol. 211, pp. 22–33, May. 2019. <https://doi.org/10.1016/j.ijpe.2019.01.032>
- [23] P. Pławiak, M. Abdar, and U. R. Acharya, “Application of new deep genetic cascade ensemble of SVM classifiers to predict the Australian credit scoring,” *Appl. Soft Comput. J.*, vol. 84, p. 105740, Nov. 2019. <https://doi.org/10.1016/j.asoc.2019.105740>
- [24] X. Huang, X. Liu, and Y. Ren, “Enterprise credit risk evaluation based on neural network algorithm,” *Cogn. Syst. Res.*, vol. 52, pp. 317–324, Dec. 2018. <https://doi.org/10.1016/j.cogsys.2018.07.023>
- [25] X. Ye, D. Lu-an, and D. Ma, “Loan evaluation in P2P lending based on Random Forest optimized by genetic algorithm with profit score,” *Electron. Commer. Res. Appl.*, vol. 32, pp. 23–36, Nov-Dec. 2018. <https://doi.org/10.1016/j.elerap.2018.10.004>
- [26] K. Cheng *et al.*, “SecureBoost: A Lossless Federated Learning Framework,” *IEEE Intell. Syst.*, vol. 36, no. 6, pp. 87–98, Nov.-Dec. 2021. <https://doi.org/10.1109/MIS.2021.3082561>
- [27] K. Masmoudi, L. Abid, and A. Masmoudi, “Credit risk modeling using Bayesian network with a latent variable,” *Expert Syst. Appl.*, vol. 127, pp. 157–166, Aug. 2019. <https://doi.org/10.1016/j.eswa.2019.03.014>
- [28] Y. Song, Y. Wang, X. Ye, D. Wang, Y. Yin, and Y. Wang, “Multi-view ensemble learning based on distance-to-model and adaptive clustering for imbalanced credit risk assessment in P2P lending,” *Inf. Sci.*, vol. 525, pp. 182–204, Jul. 2020. <https://doi.org/10.1016/j.ins.2020.03.027>
- [29] D. Liang, T. Chih-Fong, D. An-Jie, and W. Eberle, “A novel classifier ensemble approach for financial distress prediction,” *Knowl. Inf. Syst.*, vol. 54, pp. 437–462, May. 2018. <https://doi.org/10.1007/s10115-017-1061-1>
- [30] Y. O. Serrano-Silva, Y. Villuendas-Rey, and C. Yáñez-Márquez, “Automatic feature weighting for improving financial Decision Support Systems,” *Decis. Support Syst.*, vol. 107, pp. 78–87, Mar. 2018. <https://doi.org/10.1016/j.dss.2018.01.005>
- [31] G. De Tre, A. Hallez, and A. Bronselaer, “Performance optimization of object comparison,” *Int. J. Intell. Syst.*, vol. 24, no. 10, pp. 1057–1076, Jul. 2009. <https://doi.org/10.1002/int.20373>
- [32] P. Mahata, G. Chandra. Mahata, and S. Kumar. De, “An economic order quantity model under two-level partial trade credit for time varying deteriorating items,” *Int. J. Syst. Sci. Oper. Logist.*, vol. 7, no. 1, pp. 1–17, May. 2020. <https://doi.org/10.1080/23302674.2018.1473526>
- [33] Y. Li-Li, Q. Yi-Wen, H. Yuan, and R. Zhao-Jun, “A Convolutional Neural Network-Based Model for Supply Chain Financial Risk Early Warning,” *Comput. Intell. Neurosci.*, vol. 2022, p. 7825597, Apr. 2022. <https://doi.org/10.1155/2022/7825597>
- [34] W. Cheng-Feng, H. Shian-Chang, C. Chei-Chang, and W. Yu-Min, “A predictive intelligence system of credit scoring based on deep multiple kernel learning,” *Appl. Soft Comput.*, vol. 111, p. 107668, Nov. 2021. <https://doi.org/10.1016/j.asoc.2021.107668>
- [35] W. Yang and L. Gao, “A Study on RB-XGBoost Algorithm-Based e-Commerce Credit Risk Assessment Model,” *J. Sensors*, vol. 2021, p. 7066304, Oct. 2021. <https://doi.org/10.1155/2021/7066304>
- [36] S. Lahmiri, A. Giakoumelou, and S. Bekiros, “An adaptive sequential-filtering learning system for credit risk modeling,” *Soft Comput.*, vol. 25, no. 13, pp. 8817–8824, May. 2021. <https://doi.org/10.1007/s00500-021-05833-y>
- [37] X. Ye, L. an Dong, and D. Ma, “Loan evaluation in P2P lending based on Random Forest optimized by genetic algorithm with profit score,” *Electron. Commer. Res. Appl.*, vol. , pp. 23–36, Nov-Dec. 2018. <https://doi.org/10.1016/j.elerap.2018.10.004>
- [38] S. Luo, M. Xing, and J. Zhao, “Construction of Artificial Intelligence Application Model for Supply Chain Financial Risk Assessment,” *Sci. Program.*, vol. 2022, p. 4194576, Jun. 2022. <https://doi.org/10.1155/2022/4194576>
- [39] H. Zeng, “Credit Risk Evaluation in Enterprise Financial Management by Using Convolutional Neural Network under the Construction of Smart City,” *Secur. Commun. Networks.*, vol. 2022, p. 8532918, Aug. 2022. <https://doi.org/10.1155/2022/8532918>
- [40] A. Merćep, L. Mrćela, M. Birov, and Z. Kostanjčar, “Deep neural networks for behavioral credit rating,” *Entropy*, vol. 23, no. 1, Dec. 2021. <https://doi.org/10.3390/e23010027>
- [41] G. Yangyudongnanxin, “Financial Credit Risk Control Strategy Based on Weighted Random Forest Algorithm,” *Scientific Programming*, vol. 2021, p. 6276155, Oct. 2021. <https://doi.org/10.1155/2021/6276155>
- [42] Y. Xi and Q. Li, “Improved AHP Model and Neural Network for Consumer Finance Credit Risk

- Assessment,” *Advances in Multimedia*, vol. 2022, p. 9588486, Jul. 2022. <https://doi.org/10.1155/2022/9588486>
- [43] J. R. de Castro Vieira, F. Barboza, V. A. Sobreiro, and H. Kimura, “Machine learning models for credit analysis improvements: Predicting low-income families’ default,” *Appl. Soft Comput. J.*, vol. 83, p. 105640, Oct. 2019. <https://doi.org/10.1016/j.asoc.2019.105640>
- [44] W. Liu, H. Fan, and M. Xia, “Multi-grained and multi-layered gradient boosting decision tree for credit scoring,” *Appl. Intell.*, vol. 52, pp. 5325–5341, Mar. 2022. <https://doi.org/10.1007/s10489-021-02715-6>
- [45] B. Li, “Online Loan Default Prediction Model Based on Deep Learning Neural Network,” *Computational Intelligence and Neuroscience*, vol. 2022, p. 4276253, Aug. 2022. <https://doi.org/10.1155/2022/4276253>
- [46] M. Almutairi, F. Stahl, and M. Bramer, “ReG-Rules: An Explainable Rule-Based Ensemble Learner for Classification,” *IEEE Access*, vol. 9, pp. 52015–52035, Feb. 2021. <https://doi.org/10.1109/ACCESS.2021.3062763>
- [47] W. Liu, H. Fan, and M. Xia, “Step-wise multi-grained augmented gradient boosting decision trees for credit scoring,” *Eng. Appl. Artif. Intell.*, vol. 97, p. 104036, Jan. 2021. <https://doi.org/10.1016/j.engappai.2020.104036>
- [48] M. Yin and G. Li, “Supply Chain Financial Default Risk Early Warning System Based on Particle Swarm Optimization Algorithm,” *Mathematical Problems in Engineering*, vol. 2022, p. 7255967, 2022. <https://doi.org/10.1155/2022/7255967>
- [49] Z. Hassani, M. Alambardar Meybodi, and V. Hajihashemi, “Credit Risk Assessment Using Learning Algorithms for Feature Selection,” *Fuzzy Inf. Eng.*, vol. 12, no. 4, pp. 529–544, Jun. 2020. <https://doi.org/10.1080/16168658.2021.1925021>
- [50] L. Wang and H. Song, “E-Commerce Credit Risk Assessment Based on Fuzzy Neural Network,” *Computational Intelligence and Neuroscience*, vol. 2022, p. 3088915, Jan. 2022. <https://doi.org/10.1155/2022/3088915>
- [51] N. H. Putri, M. Fatekurohman, and I. M. Tirta, “Credit risk analysis using support vector machines algorithm,” *J. Phys. Conf. Ser.*, vol. 1836, p. 012039, 2021. <https://doi.org/10.1088/1742-6596/1836/1/012039>
- [52] S. Barua, D. Gavandi, P. Sangle, L. Shinde, and J. Ramteke, “Swindle: Predicting the Probability of Loan Defaults using CatBoost Algorithm,” *5th Int. Conf. Comput. Methodol. Commun.*, Erode, India, 2021, pp. 1710–1715. <https://doi.org/10.1109/ICCMC51019.2021.9418277>
- [53] Y. Liu and L. Huang, “Supply chain finance credit risk assessment using support vector machine–based ensemble improved with noise elimination,” *International Journal of Distributed Sensor Networks*, vol. 16, no. 1, Feb. 2020. <https://doi.org/10.1177/1550147720903631>
- [54] A. L. Leal Fica, M. A. Aranguiz Casanova Y J. Gallegos Mardones. “Análisis De Riesgo Crediticio, Propuesta Del Modelo Credit Scoring”. *Redalyc*, vol. 26, no. 1, pp.181-207, 2018. <https://doi.org/10.18359/rfce.2666>
- [55] Q. Liu, C. Wu, and L. Lou, “Evaluation research on commercial bank counterparty credit risk management based on new intuitionistic fuzzy method,” *Soft Comput.*, vol. 22, pp. 5363–5375, Feb. 2018. <https://doi.org/10.1007/s00500-018-3042-z>
- [56] V. B. Djeundje and J. Crook, “Identifying hidden patterns in credit risk survival data using Generalised Additive Models,” *Eur. J. Oper. Res.*, vol. 277, no. 1, pp. 366–376, Aug. 2019. <https://doi.org/10.1016/j.ejor.2019.02.006>
- [57] D. Mhlanga, “Financial inclusion in emerging economies: The application of machine learning and artificial intelligence in credit Risk assessment,” *Int. J. Financ. Studies.*, vol. 9, no. 3, Jul. 2021. <https://doi.org/10.3390/ijfs9030039>
- [58] A. Datta Chaudhuri, S. K. Biswas, S. Sarkar, A. N. Boruah, M. Chakraborty, and B. Purkayastha, “Transparent Neural based Expert System for Credit Risk (TNESCR): An Automated Credit Risk Evaluation System,” *2020 Int. Conf. Comput. Perform. Eval. ComPE*, Shillong, India, 2020, pp. 013–017. <https://doi.org/10.1109/ComPE49325.2020.9199998>
- [59] P. Z. Lappas and A. N. Yannacopoulos, “A machine learning approach combining expert knowledge with genetic algorithms in feature selection for credit risk assessment,” *Applied Soft Computing*, vol. 107, p. 107391, Aug. 2021. <https://doi.org/10.1016/j.asoc.2021.107391>