




# Credit Risk Management in the Financial Sector Using Machine Learning as a Tool: A Systematic Literature Review

Kevin Espinoza Alvarado<sup>1</sup>, Renzo Vallenias Santillan<sup>1</sup>, and Emily Baca Marroquin, MA<sup>1</sup>

<sup>1</sup>Universidad Tecnológica del Perú, Perú, u19210372@utp.edu.pe, u18203779@utp.edu.pe, abaca@utp.edu.pe

*Abstract– Several techniques are used in Credit Risk Management in the financial sector. Among them, the Machine Learning tool is different and innovative. Many companies have started to ignore traditional algorithms and look for more modern tools that present challenges. In this systematic literature review (SLR), the PRISMA methodology was used to identify the 20 selected papers, the results of which were obtained to address the topic of SLR. In this sense, it has been identified that in the last 5 years, a considerable number of research addresses the topic of credit risk management using Machine Learning as a tool within the financial sector. In summary, Machine Learning is a tool capable of accurately predicting credit risks, based on the client's financial data information compared to the accuracy obtained from traditional algorithms. However, its use also generates certain disadvantages, such as the high hardware and software implementation costs and other complexities generated in the implementation process.*

*Keywords-- Risk Management, Credit Risk, Machine Learning, Algorithms, Financial Sector.*

**Digital Object Identifier:** (only for full papers, inserted by LACCEI).

**ISSN, ISBN:** (to be inserted by LACCEI).

**DO NOT REMOVE**

# La Gestión de Riesgos Crediticios en el sector financiero usando como herramienta el Machine Learning: Una Revisión Sistemática de la Literatura

Kevin Espinoza Alvarado<sup>1</sup>, Renzo Vallenas Santillan<sup>1</sup>, and Emily Baca Marroquin, MA<sup>1</sup>

<sup>1</sup>Universidad Tecnológica del Perú, Perú, u19210372@utp.edu.pe, u18203779@utp.edu.pe, abaca@utp.edu.pe

*Resumen– Existen diversas técnicas que se utilizan en la Gestión de Riesgos Crediticios en el sector financiero. Entre ellas la herramienta Aprendizaje Automático resulta diferente e innovador. Una gran parte de las empresas han empezado a ignorar los algoritmos tradicionales y han buscado herramientas más modernas que también presentan algunos retos. En la presente Revisión Sistemática de la Literatura (RSL) se empleó la metodología PRISMA para identificar los 20 documentos seleccionados a partir de los cuales se han obtenido resultados que han permitido abordar el tema de la RLS. En ese sentido, se ha identificado que en los últimos 5 años hay un número considerable de investigaciones que abordan el tema de la gestión de riesgos crediticios empleando Machine Learning como herramienta dentro del sector financiero. En síntesis, el Machine Learning resulta ser una herramienta capaz de predecir con alta precisión los riesgos crediticios tomando como base la información de los datos financieros de los clientes comparados con la precisión obtenida a partir del empleo de algoritmos tradicionales. Sin embargo, su empleo también genera ciertas desventajas como el costo elevado en la implementación de hardware y software, y otras complejidades generadas en el proceso de implementación.*

*Palabras Claves-- Gestión de Riesgos, Riesgos Crediticios, Aprendizaje Automático, Algoritmos, Sector Financiero.*

## I. INTRODUCCIÓN

El análisis de riesgos se ha convertido en un tema crucial en las empresas debido a algunas situaciones no previstas acontecidas recientemente como la COVID-19. En el campo financiero, el análisis de los Riesgos Crediticios es vital para la toma de decisiones en una empresa [1], y ese análisis es parte de la Gestión de Riesgos Crediticios. Por tanto, este es uno de los principales aspectos de interés en las empresas financieras porque permite predecir sus ingresos a partir de los créditos que otorgan las empresas financieras a sus clientes [2]. Uno de los objetivos principales de la Gestión de Riesgos Crediticios es minimizar el riesgo de pérdida de ingresos que pueden tener las empresas financieras. Una adecuada Gestión de Riesgos Crediticios garantiza una mayor estabilidad en el área financiera de las empresas y a consecuencia atrae a inversionistas. Por ello, el empleo de Machine Learning, para la Gestión de Riesgos de empresas financieras resulta de gran apoyo en la identificación de patrones y reconocimiento de datos que suelen ser ignorados o no identificados en los procesos realizados actualmente constituyendo una ventaja

para optimizar los procesos financieros y contar con evidencias más precisas para una toma de decisiones más informada [3].

Por lo anterior, varias empresas del sector financiero han empezado a implementar Machine Learning entre otras herramientas similares para una adecuada Gestión de Riesgos Financieros. Además, este proceso de implementación ha sido documentado resultando muy favorable su uso con algunas dificultades tecnológicas en su implementación. En esa línea, la Revisión Sistemática de la Literatura (RSL) aborda el impacto, relevancia y ventaja del empleo de Machine Learning en la gestión de riesgos financieros, específicamente la Gestión de riesgos crediticios

Entre los resultados sobre las ventajas y limitaciones del uso de Machine Learning en el sector financiero se relaciona con la privacidad de datos de sus clientes ya que se emplea una gran cantidad de datos financieros y personales generando una gran preocupación en los clientes [4]. Otra preocupación se relaciona al tema de ciberataques que podrían sufrir las entidades financieras por no contar con sistemas de seguridad adecuados y corriendo el riesgo de que los datos de clientes pueden ser vendidos por terceros [5]. Finalmente, las limitaciones identificadas se relacionan con la inversión requerida que implementar las herramientas tecnológicas debido a que dicha implementación podría necesitar una infraestructura óptima a nivel de hardware lo que supondrá un elevado costo adquirirlo que luego va a requerir mantenimiento periódico [6].

Considerando las ventajas y desventajas existentes, se ha decidido investigar el impacto del uso de la herramienta de Machine Learning en la Gestión de Riesgos Crediticios en el sector financiero. El análisis permitirá apoyar a las empresas del sector financiero para estar más seguras de sus ingresos y obtener inversión por la mayor seguridad de los datos que se han encontrado y su análisis. Esta investigación explora datos sobre aplicaciones del Machine Learning en la Gestión de Riesgos Crediticios y su uso como una herramienta en el sector financiero. Debido a que las empresas necesitan saber con certeza los riesgos a los que se exponen y la forma de mitigación para tener los mejores ingresos. En suma, la presente RSL pretende dar a conocer si la herramienta Machine Learning brinda resulta beneficiosa o no al aplicarse en la Gestión de Riesgos Crediticios [1] a partir de investigaciones publicadas.

**Digital Object Identifier:** (only for full papers, inserted by LACCEI).

**ISSN, ISBN:** (to be inserted by LACCEI).

**DO NOT REMOVE**

En este contexto, la RSL está organizada de la siguiente manera. La sección II presenta la metodología empleada incluyendo la pregunta PICO formulada para la revisión sistemática y los procedimientos desarrollados en la elección del material publicado discutido en este documento. La sección III presenta los resultados mediante tablas y gráficos que han sido obtenidos a partir de las publicaciones sobre el tema. Siguiendo con la sección IV se planteará la discusión sobre a partir de los resultados obtenidos en la sección 3. Para culminar, la sección V se presentarán las conclusiones que sintetiza de manera breve los principales hallazgos y las limitaciones encontradas en la presente RSL y plantea futuras líneas de investigaciones sobre el tema.

## II. METODOLOGÍA

En la RSL se aplicaron 2 métodos los cuales son el PICO y PRISMA. Con el primero se realizó el planteamiento de la pregunta estructurada que guió la RSL, a partir de la pregunta PICO y de la identificación de los componentes se establecieron diversas palabras claves que luego permitieron elaborar una ecuación de búsqueda que se empleó para realizar una búsqueda en Scopus y lograr la extracción de los datos.

En primer lugar, se decidió usar el método PICO empleando los siguientes componentes: la población, la intervención, la comparación y los resultados [6], una estructura conocida y comúnmente utilizada en la Revisión Sistemática de la Literatura .

A partir de la definición de los componentes, se formuló la siguiente pregunta: ¿Qué herramientas del Machine Learning han ayudado a la mejora de la Gestión de Riesgos Crediticios usando los datos financieros de los clientes, originándose ventajas y desventajas en el sector financiero? Luego se elaboraron las preguntas derivadas por cada componente del PICO como se muestra en la Fig.1.

RQ: ¿Qué herramientas del Machine Learning han ayudado a la mejora de la Gestión de Riesgos Crediticios usando los datos financieros de los clientes, originándose ventajas y desventajas en el sector financiero?
RQ1: ¿Qué datos financieros se han usado?
RQ2: ¿Qué herramientas de Machine Learning se han empleado?
RQ3: ¿Cómo ha mejorado la Gestión de Riesgos Crediticios a partir del uso del Machine Learning?
RO4: ¿Qué ventajas v desventajas ha logrado el sector

Fig. 1. Preguntas PICO

A partir de las preguntas elaboradas en relación con los componentes del acrónimo PICO, en la Tabla I se definieron las palabras claves en inglés relacionadas identificadas con el empleo de tesauros que permitieron identificar varias palabras

a ser empleadas en la ecuación de búsqueda para identificar investigaciones publicadas en las bases de datos [7].

Con ello, se obtuvo las palabras relacionadas con cada componente del PICO, con estas palabras se armó la ecuación de búsqueda, la cual se colocó en la sección de búsqueda de Scopus para buscar las publicaciones que están relacionados con esta revisión. Seguidamente, se mostrará la ecuación de búsqueda armada: ("Financial data" OR "financial reporting" OR "banking situation" OR "financial analysis" OR "debt" OR "credit history" OR "credit report" OR "customer information" OR "amount due" ) AND ( "Machine Learning" OR "ML" OR "Deep Learning" OR "Federated Learning" OR "Ensemble Learning" OR "Robot Learning" OR "artificial intelligence" OR "prediction methods" OR "predictive analytics" OR "statistical Learning" OR "artificial neural networks" OR "Regression analysis" OR "Learning systems" OR "Recurrent neural networks" OR "algorithm" OR "Algorithm Management" OR "Big Data" OR "linear programming" OR "nonlinear programming" ) AND ( "Financial data processing" OR "risk management" OR "risk analysis" OR "risk assessment" OR "Financial Decision-Making" OR "Financial Data Analysis" OR "Business Management" ) AND ( "Financial sector" OR "banking" OR "finance" OR "financial services" OR "financial companies" OR "financial markets" )

TABLA I  
TABLA PICO

Componente PICO		Palabras claves en inglés	
P	Población	Datos financieros de los clientes	Financial data, financial reporting, banking situation, financial analysis, debt, credit history, credit report, customer information, amount due
I	Intervención	Machine Learning	Machine Learning, ML, Deep Learning, Federated Learning, Ensemble Learning, Robot Learning, artificial intelligence, prediction methods, predictive analytics, statistical Learning, artificial neural networks, Regression analysis, Learning systems, Recurrent neural networks, algorithm, Algorithm Management, Big Data, linear programming, nonlinear programming
C	Comparación	-	-
O	Resultados	Mejora de la Gestión de Riesgos Crediticios	Financial data processing, risk management, risk análisis, risk assessment, Financial Decision-Making, Financial Data Analysis, Business Management.
C	Contexto	Sector financiero	Financial sector, banking, finance, financial services, financial companies, financial markets

Consecutivamente, se empleó la ecuación de búsqueda en la sección de búsqueda de Scopus resultando 1371 publicaciones. En los resultados obtenidos se identificaron publicaciones no relacionadas directamente con el tema de la

revisión. Para seleccionar las publicaciones que serán parte de la revisión se aplicó el protocolo PRISMA empleado en las revisiones de literatura [7]. El diagrama de flujo PRISMA presenta una sección donde se realiza el filtrado a partir de criterios de inclusión y exclusión definidos por el investigador. Por ello en la Tabla II y Tabla III se presentan los criterios empleados para realizar el cribado de los documentos.

Seguidamente, se procedió a utilizar el Diagrama de Flujo de PRISMA (Fig.2). El filtrado se logra teniendo en cuenta varios aspectos que son desarrollados en tres momentos: Identificación, Cribado e Incluidos.

TABLA II  
CRITERIOS DE INCLUSIÓN

Criterios de inclusión	
Características del estudio	Los estudios deben ser RSL y artículos científicos.
Características de interés de los casos de estudio	Los estudios enfocados en el uso de Machine Learning en el sector financiero.
Localización geográfica o contexto del estudio	Los estudios centrados en el sector financiero.
Idioma	Los estudios en inglés y en español.

TABLE III  
CRITERIOS DE EXCLUSIÓN

Criterios de exclusión	
Características del estudio	Los estudios que no se enfoquen en la gestión de riesgos crediticios
Características de interés de los casos de estudio	Los estudios enfocados en otras áreas del sector financiero como la bolsa de valores.
Fecha de publicación	Los estudios publicados antes del 2018.

De acuerdo con el diagrama de flujo, primero se identifican los registros identificados en las bases de datos consultadas. Para esta revisión se empleó la base de datos de Scopus que a partir del empleo de la ecuación de búsqueda resultaron 1371 documentos elegibles. En un segundo momento durante la fase de cribado se excluyeron 706 registros de publicaciones que no guardaban relación con el tema de la revisión basándose a la revisión del título y el resumen de la publicación. A partir de la primera exclusión resultaron 665 publicaciones recuperadas para evaluación. Luego se procedió a descargar los archivos completos de los cuales 297 publicaciones no pudieron ser descargadas resultando en 368 publicaciones con acceso a la información completa. A partir de ello se procedió a la lectura completa de las publicaciones que fueron examinadas tomando en cuenta los criterios de inclusión y exclusión quedando un total de 20 publicaciones. Dichas publicaciones serán la base para realizar

la presente revisión sistemática según se muestra en el diagrama del flujo PRISMA (Fig. 2).

### III. RESULTADOS

A continuación, en esta sección se presentan los resultados que permitirán examinar la siguiente pregunta ¿Qué herramientas de Machine Learning han ayudado a la mejora de la Gestión de Riesgos Crediticios usando los datos financieros de los clientes, originándose ventajas y desventajas en el sector financiero? Dicha pregunta ha sido evaluada a partir de las 20 publicaciones seleccionadas al aplicar la metodología PRISMA [8].

#### Diagrama de flujo PRISMA

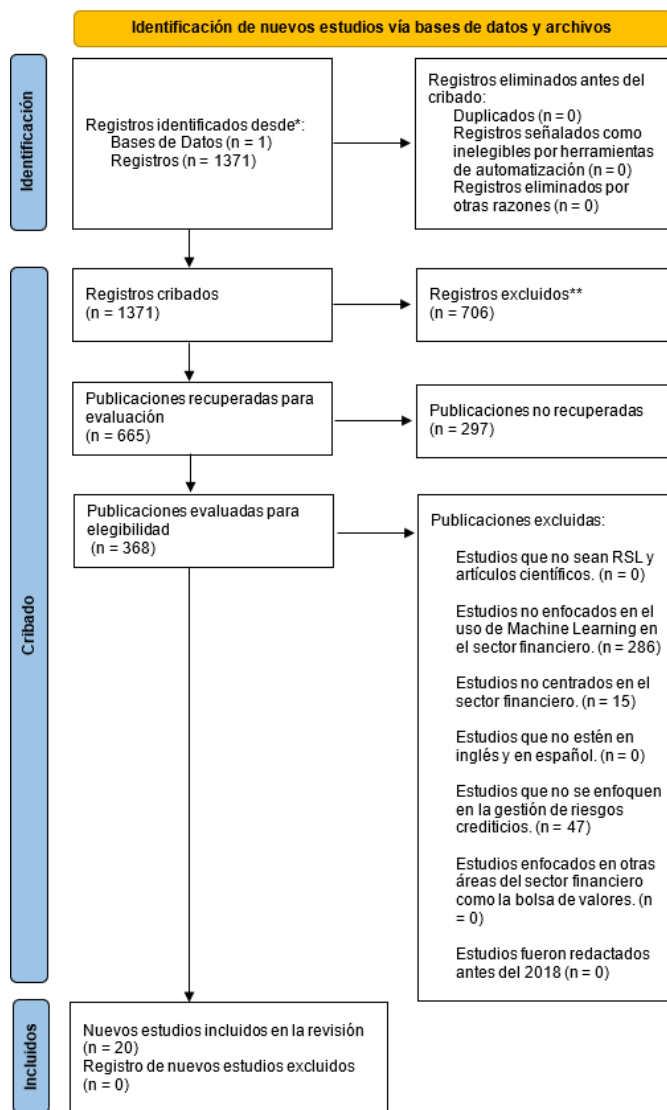


Fig. 2. Diagrama de flujo PRISMA.

En primer lugar, se emplearon las palabras clave de cada publicación para evaluar las relaciones establecidas entre ellas

mediante una red de relaciones presentadas en la Fig. 3. Donde se puede observar las diversas relaciones entre las palabras claves y la conformación de hasta cuatro distintos grupos liderados por la palabra clave “*Financial data processing*” que presenta una mayor tendencia definida por el tamaño del círculo y la intensidad de las relaciones que se establecen con otras palabras clave de menor jerarquía visibles con el color rojo.

Por otra parte, la Fig. 4 gráfica la cantidad de autores que han publicado anualmente desde el año 2018 al año 2023 sobre la temática propuesta en la presente RSL. Siendo el 2022 el año más productivo con 7 publicaciones totales respecto a este tema de investigación comparado con el año 2021 donde sólo se publicaron 2 artículos. La gráfica permite afirmar que en estos últimos años la herramienta Machine y las distintas herramientas derivadas de ella, están teniendo una gran relevancia en la aplicación en el sector financiero [9].




Fig. 3. Gráfico de palabras claves

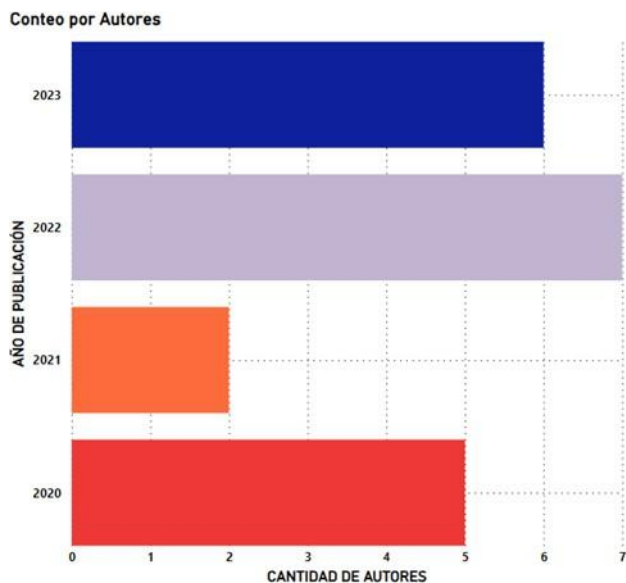


Fig. 4. Conteo de autores por año de publicación.

Seguidamente se definieron varios contextos de aplicación y se establecieron las herramientas derivadas del Machine Learning que se han reportado en las investigaciones publicadas incluidas en la presente RSL. De tal manera, en la Fig. 5 se contabilizan las herramientas de Machine Learning aplicadas en el contexto de la gestión de riesgos crediticios del sector financiero. De esa forma se evidencia que Machine Learning es una de las herramientas más empleadas para la gestión de riesgo crediticio [10] a partir de los documentos revisados en esta RSL. Por otro lado, la gráfica indica que existen otras herramientas que están siendo implementadas y empezando a tomar relevancia, aunque no son usadas mayoritariamente.

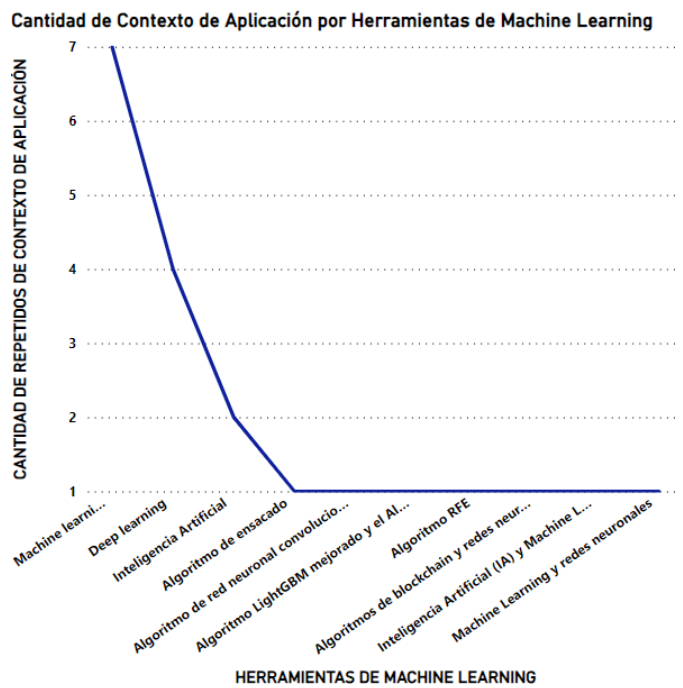


Fig. 5. Gráfico de Cantidad de Contexto de Aplicación por Herramienta de Machine Learning.

A partir de la formulación de la pregunta PIOC se elaboraron 4 preguntas para cada componente de PIOC y se han recolectados los datos sistemáticamente respecto de cada pregunta a partir del empleo de formularios de extracción de información. La información recolectada ha sido analizada y se presentaran los alcances para las 4 preguntas empezando por RQ1: ¿Qué datos financieros se han usado?

Con relación a los datos financieros se ha identificado que en general provienen de bases de datos actualizadas frecuentemente por cada institución financiera. En la revisión, se ha observado que muchos documentos cuentan con una gran

cantidad de datos. Seguidamente la Tabla IV presenta el top 5 de las publicaciones con mayor volumen de datos analizados en números.

En la Tabla IV, los datos reportados por las publicaciones oscilan desde 1.4 millón de datos usados a casi 4 millones de datos. Las otras publicaciones si bien emplearon muchos datos, no especificaron el volumen de datos en la publicación por ello no se han reportado en la Tabla IV.

TABLE IV  
VOLUMEN DE DATOS FINANCIEROS

Título de la publicación	Volumen de datos encontrados
Deep Learning in the stock market—a systematic survey of practice, backtesting, and applications [17]	3210654
A Bayesian-based classification framework for financial time series trend prediction [18]	1922605
A high-frequency approach to VaR measures and forecasts based on the HAR-QREG model with jumps [19]	1652301
Online portfolio selection with predictive instantaneous risk assessment [20]	1465231
The Construction of Corporate Financial Management Risk Model Based on XGBoost Algorithm [21]	N/A

En cuanto a la pregunta ¿Qué herramientas de Machine Learning se han empleado? se presentan las herramientas de Machine Learning más usadas en las publicaciones. Fig. 6 presenta las distintas herramientas reportadas más empleadas en las 20 publicaciones seleccionadas resultando Machine Learning con 35%. Seguida por Deep Learning con el 20%. Por otro lado, se observa que distintos algoritmos, redes neuronales son menos usadas con sólo un 5%.

Fig. 7 presenta la relación del porcentaje de métodos de investigación actuales basados en Machine Learning destacando los algoritmos de predicción que son utilizados en la gestión de riesgos que ayudan a prever riesgos financieros, permitiendo a las empresas en la toma de decisiones [11].




Fig. 6. Porcentaje de herramientas de Machine Learning usadas en las publicaciones.

Ahora se responderá a la siguiente pregunta PICO: RQ3: ¿Cómo ha mejorado la Gestión de Riesgos Crediticios a partir del uso del Machine Learning?

Después de la extracción de datos para responder esta pregunta se deduce globalmente que la herramienta Machine Learning ha causado un gran impacto positivo en la Gestión de Riesgos Crediticios en los cuales resalta mejores predicciones en casos de activos, préstamos a clientes y una mejor toma de decisiones de las empresas.

Porque se ha encontrado resultados como “se ha encontrado las características principales para que el cliente sea un buen prestatario” que son suficientes para poder deducir el resultado global presentado anteriormente que da respuesta a la pregunta PICO.




Fig. 7. Gráfico de porcentaje de métodos de investigación actuales basados en Machine Learning utilizados en las publicaciones.

Ahora para la última pregunta PICO ¿Qué ventajas y desventajas ha logrado el sector financiero al implementar el Machine Learning? Se presentan los resultados a partir de 3 gráficas que muestran las ventajas logradas en el sector financiero al implementar el Machine Learning en las publicaciones.

En la Fig. 8, se muestran las distintas ventajas que se han encontrado en las 20 publicaciones obtenidas utilizando la herramienta Machine Learning o derivadas de esta. La mayoría de las ventajas favorece la prevención de riesgos de la empresa al analizar los datos con la herramienta Machine Learning, otras de las ventajas es la capacidad de determinar la aptitud del cliente para darle un préstamo que es una ventaja muy



significativa para empresas que brindan créditos a sus clientes.

Fig. 8. Gráfico de la cantidad de ventajas que ha logrado el sector financiero al implementar el Machine Learning en las publicaciones.

La Fig. 9 presenta las desventajas al implementar el Machine Learning en el sector financiero identificadas en las publicaciones. Una de las desventajas más preocupante es que sin la tecnología adecuada no se podría utilizar los datos para la predicción de riesgos, ya que se utilizan algoritmos muy complejos [12]. También aumenta el riesgo a nivel de ciberseguridad si no se cuenta con los hardware y software necesarios para prevenir ataques cibernéticos [13].



Fig. 9. Desventajas al implementar Machine Learning.

Ahora por último se presentan las definiciones de Machine Learning de las publicaciones. En la Fig. 10, se muestra las distintas definiciones de Machine Learning en las publicaciones revisados en la RSL. Un 10% definen como un enfoque de aprendizaje tradicional que alude al uso algoritmos y enfoques que se han utilizado antiguamente.




Fig. 10. Gráfico de porcentaje de definiciones de Machine Learning de las publicaciones. (Edición propia)

Para terminar también se presentan las definiciones de la herramienta Machine Learning en la Gestión de Riesgos Crediticios. La tabla V muestra las definiciones que le dan al Machine Learning las distintas publicaciones, así como la cantidad de publicaciones que tiene dicha definición. Donde se destaca que Machine Learning es utilizada para la Gestión de

Riesgos Crediticios, el procesamiento de datos, para la predicción de datos y para que las empresas tengan una mejor toma de decisión.

Con ello se tiene que el resultado de la investigación es que existen varias herramientas del Machine Learning que han ayudado a la mejora de la Gestión de Riesgos Crediticios usando los datos financieros de los clientes, originándose ventajas y desventajas en el sector financiero, se ha analizado qué herramientas de estas son las más usadas y que estas producen ventajas como desventajas pero que en general según los datos observados se puede decir que por ventajas descritas, es una forma muy correcta y buena de mejorar la Gestión de Riesgos Crediticios.

TABLE V  
DEFINICIONES POR CANTIDADES DE PUBLICACIONES

Definiciones de Machine Learning en cada publicación	Cantidad de publicaciones
Tecnología para analizar la Big Data en los procesos de gestión de riesgos mediante minería de textos y análisis de sentimientos.	1
Sirve para analizar la correlación entre los valores de los atributos y transformar los datos en conocimiento necesario para la toma de decisiones.	1
Predictor de movimientos en los mercados financieros.	1
Herramienta para monitorear la relación comercial con grandes conjuntos de datos.	1
Herramienta para el diagnóstico de quiebras corporativas.	1
Herramienta analizadora basándose en estadísticas fundamentales del desempeño de la empresa que se miden como resultados trimestrales.	1
Herramienta para predecir la evaluación de riesgos en las finanzas corporativas.	1
Herramienta para modelar datos altamente desequilibrados para detectar fraude crediticio.	1
Es una tecnología para revisar las pérdidas máximas que una empresa puede recibir con una probabilidad determinada.	1
Es una tecnología para analizar el riesgo de incumplimiento crediticio.	1
Es una herramienta para la precisión de la solvencia crediticia y el perfil de riesgo del público.	1
Es una herramienta para la lectura de datos históricos y así poder hacer predicciones sobre nuevos datos.	1
Es un predictor de precios de los activos.	1
Es un modelo de evaluación de riesgos financieros para determinar la crisis financiera de una empresa o emprendimiento.	1
Es un enfoque de aprendizaje tradicional.	2
Es un algoritmo que estudia el riesgo crediticio del financiamiento de las pequeñas y medianas empresas "PYME" desde la perspectiva del financiamiento de la cadena de suministro	1
Es un algoritmo para pronosticar las series de tiempo financieras.	1
Es parte de las aplicaciones emergentes de herramientas y técnicas informáticas avanzadas	1
No específica	1

#### IV. DISCUSIÓN

##### A. Usos de la herramienta Machine Learning en el sistema financieros:

La herramienta Machine Learning en el último lustro ha sido utilizado de varias formas dentro de la Gestión de Riesgos Crediticios. Los resultados que se han obtenido en esta investigación nos indica que esta herramienta de Machine Learning y sus aplicaciones se ha orientado a las predicciones sobre el margen de riesgo del crédito otorgado a un cliente cuando éste no pueda pagarlo [14]. Asimismo, la herramienta Machine Learning analiza la Big Data de los clientes con el fin de hacer predicciones más acertadas sobre la solvencia crediticia de la empresa.

##### B. Impacto positivo en el sector financiero por el uso de la herramienta de Machine Learning:

Los resultados muestran que el impacto positivo de la herramienta Machine Learning en estas publicaciones coinciden que el riesgo ha disminuido ampliamente [15]. Puesto que se analiza el retorno de crédito que las empresas otorgan a los clientes. Lo cual satisface a las empresas brindando un crecimiento de rentabilidad [16].

##### C. Impacto negativo en el sector financiero por el uso de la herramienta de Machine Learning:

En esta RSL se han identificado al menos 2 desventajas. En primer lugar, los algoritmos son complejos lo que genera que la empresa posea un personal especializado para ello.

Otra desventaja es la fuerte inversión que tiene que realizar la empresa para poder mejorar sus tecnologías a nivel de hardware y software para el óptimo uso de esta herramienta [17].

##### D. Limitaciones del uso de Machine Learning:

Se ha detectado que no hay un análisis para el uso de los tipos de herramientas Machine Learning en los distintos contextos que puede haber en el sector financiero, se encuentra en una publicación que se usa Deep Learning [18] para una entidad bancaria, sin embargo, no se asegura que ese tipo de herramienta pueda ser usada para siempre para el contexto de una entidad bancaria, quizás eventualmente se pueda analizar en qué contexto es más favorable usar una herramienta que otra.

#### V. CONCLUSIONES

Este estudio llevó a cabo una RSL sobre la Gestión de Riesgos Crediticios en el sector financiero usando como herramienta el Machine Learning. El objetivo de esta investigación fue abordar el tema sobre el impacto del Machine Learning en el sector financiero, en la parte de la Gestión de Riesgos Crediticios con el fin de adquirir un entendimiento más amplio sobre si es realmente ventajoso o no. La revisión concluye que Machine Learning posee un gran

potencial para la utilización en el marco del tema de Gestión de Riesgos Crediticios. Los datos obtenidos muestran que varias de las herramientas de Machine Learning han presentado ventajas para la Gestión de Riesgos Crediticios y que muchas empresas las están implementando paulatinamente, generando que estas herramientas logren notoriedad en el mercado como parte de ayuda para la Gestión de Riesgos Crediticios en una entidad financiera.

Por otra parte, se identificó que hay un alza en las ventajas de aplicar las herramientas de Machine Learning y las desventajas presentan una homogeneidad en los resultados. En esta misma línea, se vio que hay herramientas de Machine Learning que se usan en contextos distintos, por lo cual se puede decir que el Machine Learning tiene un gran alcance en cuanto al contexto que se le plantea.

Para culminar, esta RSL detalla el impacto del Machine Learning en la Gestión de Riesgos Crediticios del Sector Financiero. De lo expuesto anteriormente, se ha dejado indicios de nuevos temas debido a las limitaciones, los cuales podrán ser estudiados para la complementación de esta investigación. A futuro, esta investigación servirá para introducir el estudio de temas sobre el uso de Machine Learning en las empresas financieras.

#### AGRADECIMIENTOS

Los autores Espinoza Alvarado y Vallenas Santillan desean agradecer a la Universidad Tecnológica del Perú por el apoyo en el desarrollo de la publicación, y en especial a Emily Baca Marroquín y Walter Marzal, docentes del curso Formación para la Investigación - Sistemas ya que el presente documento fue elaborado y asesorado en el marco del curso durante el semestre académico 2023-II.

#### REFERENCIAS

- [1] A. Oualid, Y. Maleh, y L. Moumoun, «Federated learning techniques applied to credit risk management: a systematic literature review», *edpacs: The EDP Audit, Control, and Security Newsletter Online*, vol. 68, n.o 1, pp. 42- 56, jul. 2023, doi: 10.1080/07366981.2023.2241647.
- [2] F. M. Assef y M. T. A. Steiner, «Ten-year evolution on credit risk research: A systematic literature review approach and discussion», *Ingeniería e Investigación*, vol. 40, n.o 2. *Revista Ingeniería e Investigación - Editorial Board*, pp. 50-71, 2020. doi: 10.15446/ing.investig.v40n2.78649.
- [3] D. Tripathi, D. R. Edla, A. Bablani, A. K. Shukla, y B. R. Reddy, «Experimental analysis of machine learning methods for credit score classification», *Progress in Artificial Intelligence*, vol. 10, n.o 3. Springer Science and Business Media Deutschland GmbH, pp. 217-243, 1 de septiembre de 2021. doi: 10.1007/s13748-021-00238-2.
- [4] S. Shi, R. Tse, W. Luo, S. D'Addona, y G. Pau, «Machine learning-driven credit risk: a systemic review», *Neural Computing and Applications*, vol. 34, n.o 17. Springer Science and Business Media Deutschland GmbH, pp. 14327-14339, 1 de septiembre de 2022. doi: 10.1007/s00521-022-07472-2.
- [5] H. Kim, H. Cho, y D. Ryu, «Corporate default predictions using machine learning: Literature review», *Sustainability (Switzerland)*, vol. 12, n.o 16. MDPI, 1 de agosto de 2020. doi: 10.3390/SU12166325.



- [6] A. Marchenko y A. Temeljotov-Salaj, «A systematic literature review of non-invasive indoor thermal discomfort detection», *Applied Sciences (Switzerland)*, vol. 10, n.o 12, pp. 1-16, jun. 2020, doi: 10.3390/APP10124085.
- [7] L. M. Bastidas-Orrego, N. Jaramillo, J. A. Castillo-Grisales, y Y. F. Ceballos, «A systematic review of the evaluation of agricultural policies: Using prisma», *Heliyon*, vol. 9, n.o 10. Elsevier Ltd, 1 de octubre de 2023. doi: 10.1016/j.heliyon.2023.e20292.
- [8] Y. Wang, «Research on Supply Chain Financial Risk Assessment Based on Blockchain and Fuzzy Neural Networks», *Wirel Commun Mob Comput*, vol. 2021, 2021, doi: 10.1155/2021/5565980.
- [9] R. Giacometti, G. Torri, G. Farina, y M. E. De Giuli, «Risk attribution and interconnectedness in the EU via CDS data», *Computational Management Science*, vol. 17, n.o 4, pp. 549-567, dic. 2020, doi: 10.1007/s10287-020-00385-2.
- [10] B. Singh et al., «ML-Based Interconnected Affecting Factors with Supporting Matrices for Assessment of Risk in Stock Market», *Wirel Commun Mob Comput*, vol. 2022, 2022, doi: 10.1155/2022/2432839.
- [11] H. Wang, K. O. Kwok, y S. Riley, «Forecasting influenza incidence as an ordinal variable using machine learning 1», doi: 10.1101/2023.02.09.23285705.
- [12] T. Vaiyapuri et al., «Intelligent Feature Selection with Deep Learning Based Financial Risk Assessment Model», *Computers, Materials and Continua*, vol. 72, n.o 2, pp. 2429-2444, 2022, doi: 10.32604/cmc.2022.026204.
- [13] G. Chakraborty, «Evolving profiles of financial risk management in the era of digitization: The tomorrow that began in the past», *J Public Aff*, vol. 20, n.o 2, may 2020, doi: 10.1002/pa.2034.
- [14] A. Hong, M. Gao, Q. Gao, y X. H. Peng, «Non-stationary financial time series forecasting based on meta-learning», *Electron Lett*, vol. 59, n.o 1, ene. 2023, doi: 10.1049/el12.12681.
- [15] J. Jemai y A. Zarrad, «Feature Selection Engineering for Credit Risk Assessment in Retail Banking», *Information (Switzerland)*, vol. 14, n.o 3, mar. 2023, doi: 10.3390/info14030200.
- [16] D. Fejza, D. Nace, y O. Kulla, «The Credit Risk Problem—A Developing Country Case Study», *Risks*, vol. 10, n.o 8, ago. 2022, doi: 10.3390/risks10080146.
- [17] K. Olorunnimbe y H. L. Viktor, «Deep learning in the stock market— A systematic survey of practice, backtesting, and applications», *Artificial Intelligence Review*, vol. 56, n.o 3, pp. 2057-2109, jun. 2022, doi: 10.1007/s10462-022-10226-0.
- [18] A. Dezhkam, M. T. M. Shalmani, A. Aghapour, A.-H. Karimi, A. Rabiee, y S. M. Shalmani, «A Bayesian-based classification framework for financial Time Series trend prediction», *The Journal of Supercomputing*, vol. 79, n.o 4, pp. 4622-4659, sep. 2022, doi: 10.1007/s11227-022-04834-4.
- [19] J. Huang, Y. Xu, y Y. Song, «A high-frequency approach to VAR measures and forecasts based on the HAR-QREG model with jumps», *Physica A: Statistical Mechanics and its Applications*, vol. 608, p. 128253, dic. 2022, doi: 10.1016/j.physa.2022.128253.
- [20] W. Xi, Z. Li, X. Song, y H. Ning, «Online portfolio selection with predictive instantaneous risk assessment», *Pattern Recognition*, vol. 144, p. 109872, dic. 2023, doi: 10.1016/j.patcog.2023.109872.
- [21] R. Qin, «The construction of Corporate Financial Management risk model based on XGBOOST Algorithm», *Journal of Mathematics*, vol. 2022, pp. 1-8, abr. 2022, doi: 10.1155/2022/2043369.