



Revista Micaela

ISSN: 2955-8646 (en línea) / 2709-8990 (impresa)
Universidad Nacional Micaela Bastidas de Apurímac
Vice Rectorado de Investigación – Perú

Vol. 5 Num. 1 (2024) - Publicado: 17/10/24
<https://doi.org/10.57166/micaela.v5.n1.2024>
Páginas: 30- 35
Recibido 01/10/2024 ; Aceptado 17/10/2024

<https://doi.org/10.57166/micaela.v5.n1.2024.134>

Autores:

1. **ORCID ID** <https://orcid.org/0009-0004-3766-6655>
Guillermo Renato Aguilar-Valenzuela, Ingeniería Informática y Sistemas de la Universidad Nacional Micaela Bastidas de Apurímac – 191186@unamba.edu.pe
2. **ORCID ID** <https://orcid.org/0000-0002-5205-3660>
Ecler Mamani-Vilca, Docente de la Universidad Nacional Micaela Bastidas de Apurímac PE, eclervirtual@unamba.edu.pe

Algoritmos para Machine Learning utilizados en la Gestión de Riesgo Crediticio en Perú

Machine Learning Algorithms used in Credit Risk Management in Peru

Guillermo Renato Aguilar-Valenzuela¹ y Ecler Mamani-Vilca²

Resumen. El objetivo del presente estudio es identificar los algoritmos de Machine Learning más utilizados y efectivos para gestionar el riesgo crediticio en el sistema financiero peruano. Se analizaron cuatro investigaciones que implementaron diferentes algoritmos, tales como Árbol de Decisión, Support Vector Machine (SVM), Random Forest, Redes Neuronales, Naive Bayes, K Nearest Neighbor (KNN) y Regresión Logística, en entidades financieras y microfinancieras. La metodología incluyó la revisión bibliográfica y la webgrafía. Los resultados mostraron que el Árbol de Decisión y el SVM fueron los algoritmos más utilizados. Por su parte, las Redes Neuronales y otros algoritmos también tuvieron un rendimiento aceptable pero no superaron a los algoritmos anteriores. Las conclusiones señalan que, siendo el Árbol de Decisión y SVM las opciones más efectivas para predecir incumplimientos de pagos y gestionar el riesgo crediticio, la elección del modelo óptimo puede depender de las características específicas de los datos y sobre todo los objetivos de cada institución financiera.

Palabras Clave: Machine Learning, riesgo crediticio.

Abstract. The purpose of this study is to identify the most used and effective Machine Learning algorithms in credit risk management in the Peruvian financial system. Four research studies were analyzed that implemented different algorithms, such as Decision Tree, Support Vector Machine (SVM), Random Forest, Neural Networks, Naive Bayes, K Nearest Neighbor and Logistic Regression, in financial and microfinance institutions. The methodology included a literature review and webgraphy. The results revealed that the most used algorithms were Decision Tree and SVM. In addition, Neural Networks and other algorithms presented acceptable performance, but did not outperform the leading models in credit risk prediction. The conclusions point out that, being Decision Tree and SVM the most effective options for predicting defaults and managing credit risk, the choice of the optimal model may depend on the specific characteristics of the data and above all the objectives of each financial institution.

Keywords: Keywords: Machine Learning, credit risk.

1 Introducción

Durante los últimos años, el aprendizaje automático o Machine Learning (ML) ha emergido como una herramienta importante en el sistema financiero global, revolucionando diversas áreas, particularmente la gestión de riesgos como lo son el riesgo de mercado, riesgo de crédito y riesgo operacional. La gestión del riesgo crediticio es de suma importancia para las instituciones financieras, ya que permite mitigar pérdidas y minimizar la vulnerabilidad frente a fluctuaciones adversas en los créditos otorgados [1].

El progreso tecnológico ha permitido a las instituciones financieras mejorar de manera eficaz la precisión de la gestión de riesgos, lo que ha llevado a una mejor toma de decisiones y a una disminución de las tasas de morosidad y fraude. La industria bancaria y financiera peruana, ha adoptado cada vez más el uso del ML. La razón principal de esto es la necesidad de mejorar la inclusión financiera entre una población diversa, que se enfrenta a desafíos únicos que requieren la aplicación del aprendizaje automático. Esto es de gran importancia, dada la creciente accesibilidad al crédito y la necesidad de evaluar a personas que a menudo carecen de formación financiera formal. Esta tendencia no sólo es indicativa de un cambio en la forma en que los bancos administran sus carteras de riesgo, sino que también refleja un esfuerzo por democratizar el crédito en un clima económico cambiante.



El propósito principal de esta investigación es analizar los algoritmos usados del Machine Learning en la gestión de riesgo crediticio en el sistema financiero peruano. Para realizar esta investigación se examinaron estudios de caso y estudios académicos de la última década sobre el uso de ML en la evaluación del riesgo crediticio en el mercado peruano. Las preguntas de esta investigación fueron ¿Qué algoritmos de ML son los usados para la gestión de riesgo crediticio en el sistema financiero peruano? ¿Cuál es el mejor algoritmo ML de los usados para la gestión de riesgo crediticio en el sistema financiero peruano?. Este estudio es relevante porque analiza el Machine Learning y la gestión de riesgo crediticio, buscando entender cómo esta tecnología puede mitigar el riesgo y mejorar la eficiencia en la evaluación crediticia.

Gomez R [2] en su estudio Machine Learning Aplicado a la Gestión de Riesgos, caso de una cartera castigada de créditos por convenios de una entidad financiera en Perú con sede en Colombia gestiona un portafolio significativo de créditos por convenios. Este tipo de crédito, dirigido a empleados de empresas públicas y privadas, es descontado directamente de la nómina por el empleador. Sin embargo, el área de gestión de riesgos enfrentaba dificultades para identificar con precisión los factores que llevaban al incumplimiento de pagos, especialmente ante el creciente y diverso número de clientes. Las metodologías tradicionales, como la regresión logística, resultaban insuficientes para abordar este problema, lo que impulsó la implementación de un modelo de Machine Learning basado en árboles de decisión. El estudio se centró en los créditos castigados durante 2020, analizando variables como edad, sueldo, género y si el cliente trabajaba en las fuerzas armadas, dado que se había observado que muchos de los clientes cesados tendían a caer en incumplimiento, a pesar de que la naturaleza de estos créditos depende del descuento directo por parte de sus empleadores.

Por su parte, Cabanillas Romero J. [3] en su trabajo titulado Eficacia de modelos Machine Learning para el pronóstico del riesgo crediticio en la cartera consumo. Coopac San José Cartavio, se abordó el problema del riesgo crediticio en las cooperativas de ahorro y crédito, especialmente en el contexto de la pandemia que incrementó significativamente la demanda de créditos. El estudio se centró en la Coopac San José Cartavio, una entidad expuesta a altos índices de morosidad, y tenía como objetivo evaluar si los modelos de Machine Learning superaban al modelo clásico de Regresión Logística en la predicción del incumplimiento de pago en su cartera de consumo. Los resultados indicaron que los modelos de Machine Learning, específicamente el Árbol de Decisión, lograron un desempeño superior en términos de precisión, lo que permitió mejorar la gestión del riesgo crediticio en comparación con el modelo tradicional de Regresión Logística.

Asimismo, Yaranga Vite I. [4] en su tesis Machine Learning para predecir el riesgo crediticio de un cliente en la Empresa FUTECH PERU S.A.C 2022 nos explica como la empresa FUTECH PERÚ S.A.C. enfrenta una problemática en la adecuada calificación de clientes en su proceso de admisión comercial, lo que genera decisiones subjetivas que pueden afectar negativamente su patrimonio. Para abordar este problema, la investigación se enfocó en el uso de Machine Learning como herramienta para automatizar el proceso de verificación y mejorar la precisión en la predicción del riesgo crediticio. Se evaluaron diversos algoritmos, como Support Vector Machine, Random Forest, Naive Bayes, K-Nearest Neighbor y Decision Tree, comparando su desempeño en términos de precisión, sensibilidad y especificidad. Los resultados mostraron que el modelo de Support Vector Machine fue el más eficaz, con un 99.8% de precisión, 100% de sensibilidad y 99.7% de especificidad, superando a los demás algoritmos y demostrando ser una solución viable para mejorar la gestión del riesgo crediticio de la empresa. Esto resalta el potencial del uso de Machine Learning para mitigar riesgos financieros y tomar decisiones más informadas y objetivas.

Finalmente, Alarcón Morales y Mora Ramos [5] en su trabajo Modelo para la evaluación del riesgo crediticio para los clientes de las microfinancieras del Perú, se estudió el impacto de implementar técnicas de minería de datos en el proceso de análisis de riesgo crediticio de una microfinanciera. La investigación se llevó a cabo en el contexto del creciente sector de microfinancieras en el Perú, el cual ha sido clave para promover la inclusión financiera al otorgar financiamiento a micro y pequeñas empresas (MYPEs), especialmente en regiones del interior del país. A pesar del impacto económico positivo que generaron estas entidades, algunas enfrentaban problemas de morosidad elevados, como el caso de la Caja Rural Señor de Luren, que reportó un índice de morosidad del 26.65% y un retorno sobre el capital (ROE) negativo del -14.11%. Frente a esta problemática, el estudio propuso la implementación de modelos de Machine Learning, como el uso de algoritmos predictivos, para mejorar la precisión y efectividad en la evaluación del riesgo crediticio. A través del análisis de big data y la construcción de modelos predictivos, el trabajo buscó superar las limitaciones de las técnicas tradicionales, como la regresión logística, que resultaban insuficientes para abordar la creciente complejidad y diversidad de las carteras de crédito de las microfinancieras peruanas.

Las revisiones de la literatura indican que el aprendizaje automático es un medio muy eficaz y avanzado para gestionar el riesgo crediticio en el sistema financiero global, con potencial para un mayor desarrollo a medida que se adopten modelos más sólidos y transparentes

1.1. Machine Learning

El Machine Learning (ML) o aprendizaje automático es una rama de la inteligencia artificial que es usada en múltiples áreas de la investigación académica, desarrollo tecnológico y predicción de datos para empresas, ya que su proceso consiste en que las computadoras adquieran conocimientos para que así mejoren de manera progresiva las tareas o trabajos que se les fueron asignados. Esto hace que las empresas en general empiecen a tomar importancia al desarrollo del aprendizaje automático [6].

Tipos de aprendizaje de Machine Learning. El aprendizaje automático se clasifica en: Machine Learning Supervisado, No Supervisado y de Refuerzo y lo define:

- **Machine Learning Supervisado.** La importancia de las técnicas de aprendizaje automático supervisado es poder aprender de un modelo a través del entrenamiento de datos financieros usando data etiquetada que permite poder realizar predicciones futuras.
- **Machine Learning No Supervisado.** En el aprendizaje automático no supervisado las técnicas funcionan sin el uso de datos etiquetados. Con estas técnicas, podemos explorar la estructura de nuestros datos para extraer información significativa y realizar agrupaciones de acuerdo a las características de la información.
- **Aprendizaje por Refuerzo.** El objetivo del aprendizaje por refuerzo consiste en desarrollar un sistema (agente) que mejore su rendimiento basado en interacciones con el entorno y sea capaz de tomar decisiones. A través de la interacción con el entorno, un agente puede utilizar el aprendizaje por refuerzo con el objetivo de aprender diferentes acciones que permitan maximizar la recompensa, es decir busca aprender a tomar acciones que conduzcan a resultados positivos, recompensas y evitar acciones que lleven a resultados negativos [6].

Árbol de Decisión. El algoritmo de Árbol de Decisión es utilizado para clasificar o predecir valores mediante una estructura jerárquica similar a un árbol. Cada nodo interno representa una característica (atributo), cada rama un resultado de esa característica, y cada hoja una clase o valor. Su principal ventaja radica en su fácil interpretación y transparencia en la toma de decisiones, lo que lo hace adecuado para la gestión del riesgo crediticio. Los árboles de decisión son útiles en situaciones donde la interpretabilidad del modelo es tan importante como su precisión, como en el caso del sector financiero [7].

Random Forest. Este es un algoritmo basado en el ensamblado de múltiples árboles de decisión. Utiliza la técnica de bagging (bootstrap aggregating), donde se crean múltiples subconjuntos de los datos originales para entrenar varios árboles. La predicción final se obtiene a través de la votación de los diferentes árboles, lo que lo hace robusto y preciso al minimizar el riesgo de sobreajuste. Random Forest ha mostrado un excelente rendimiento en aplicaciones de riesgo crediticio debido a su capacidad de manejar grandes volúmenes de datos con múltiples características [7].

Naive Bayes. Este algoritmo se basa en el teorema de Bayes, asumiendo que las características son independientes entre sí, una suposición que rara vez se cumple completamente. Sin embargo, a pesar de esta simplicidad, Naive Bayes ha demostrado ser sorprendentemente eficaz, especialmente en aplicaciones donde es necesario realizar clasificaciones rápidas y precisas con grandes volúmenes de datos. Este algoritmo es útil para modelos de clasificación cuando se dispone de datos categóricos en el análisis de riesgos crediticios [7].

K-Nearest Neighbors (KNN). KNN es un algoritmo de clasificación que asigna una etiqueta a un nuevo dato basándose en las etiquetas de los puntos de datos más cercanos en el espacio de características. Es fácil de implementar y comprender, pero puede volverse computacionalmente costoso a medida que aumenta el número de datos. KNN es efectivo en problemas de clasificación de riesgo crediticio, siempre que se disponga de una cantidad considerable de datos etiquetados para hacer comparaciones [7].

Regresión Logística. La regresión logística es un modelo estadístico utilizado para clasificar datos binarios, siendo ideal para problemas en los que se requiere una probabilidad de pertenencia a una clase (por ejemplo, incumplimiento o no). En la gestión de riesgo crediticio, este modelo ha sido muy utilizado debido a su simplicidad y efectividad, especialmente en comparación con modelos más complejos. A pesar de la introducción de algoritmos más avanzados, la regresión logística sigue siendo una herramienta valiosa en la evaluación del riesgo crediticio en instituciones financieras peruanas [7].

Redes Neuronales. Las redes neuronales artificiales son modelos de aprendizaje profundo que imitan el funcionamiento del cerebro humano, constituyendo una serie de capas de neuronas artificiales que procesan la información. En el sector financiero, se utilizan para la predicción del riesgo crediticio debido a su capacidad para detectar patrones ocultos y no lineales en grandes conjuntos de datos. Sin embargo, pueden ser más difíciles de interpretar en comparación con otros modelos [8].

Support Vector Machine (SVM). Este algoritmo busca encontrar el hiperplano óptimo que separe las diferentes clases en un espacio multidimensional, maximizando el margen entre las clases. Es particularmente eficaz para datos con dimensiones elevadas o cuando las clases no son linealmente separables, gracias al uso de funciones kernel. SVM ha demostrado una alta precisión en la predicción de incumplimientos crediticios, especialmente cuando se enfrentan datos complejos o ruidosos [8].

1.2. Riesgo Crediticio

El riesgo crediticio se refiere a la probabilidad de que un deudor no cumpla con sus obligaciones de pago, incurriendo en pérdidas financieras para el acreedor. Este riesgo es inherente a cualquier operación crediticia y puede ser influenciado por factores como la solvencia del deudor, la calidad del crédito, el entorno económico y la gestión del riesgo [9]. Por ende, para enfrentar este riesgo, las financieras consideran las pérdidas potenciales y la importancia de mantener reservas para cubrir posibles pérdidas en créditos en un momento específico. Esta tarea ha sido un reto continuo para las entidades financieras. Para entender mejor el tema se debe tener en cuenta la rentabilidad.

La rentabilidad se define como la característica de ser rentable, es decir, la capacidad de producir renta, utilidad, ganancia o beneficio. En el ámbito financiero, esto se relaciona con las finanzas, que se ocupan de la gestión de caudales o recursos monetarios. El concepto de rentabilidad financiera se vincula con las ganancias generadas a partir de determinados activos durante un periodo específico. Conocido también como ROE (Return on Equity), este término comúnmente se asocia con las ganancias que perciben los inversores [10].

2 Método

La técnica de investigación aplicada es la revisión bibliográfica y webgrafía, que se refiere a la recopilación, análisis y síntesis de información previamente publicada en fuentes académicas y web. Este enfoque permitió identificar estudios clave relacionados con la gestión del riesgo crediticio mediante Machine Learning en el sistema financiero peruano. El ámbito de estudio fue en el sector financiero peruano, específicamente en la gestión de riesgos crediticios. Se centró en el uso de Machine Learning para mejorar la evaluación y clasificación del riesgo crediticio, en entidades financieras en general de Perú. Las fuentes de información utilizadas fueron bases de datos y repositorios académicos, como también sitios web de relevancia en el ámbito financiero y tecnológico, repositorios de universidades peruanas y literatura gris: Incluyendo informes técnicos y tesis, que aportaron un análisis más específico del contexto financiero local.

Se excluyeron fuentes que no cumplieran con los siguientes criterios: falta de revisión por pares: Estudios no revisados por pares, ya que no garantizan la validez de la información científica presentada, información antes de 2010, a menos que fueran clave para el desarrollo de las bases teóricas, ya que no reflejan los avances recientes en Machine Learning.

3 Resultados

En base al objetivo principal de esta investigación, que es analizar el uso de Machine Learning (ML) en la gestión de riesgo crediticio en el sistema financiero peruano, y a las preguntas de investigación planteadas, se presentan los resultados obtenidos:

Después de la recopilación de información de los distintos trabajos que abordaron la gestión del riesgo crediticio en el sistema financiero peruano, se identificó que los algoritmos de Machine Learning más empleados han sido aquellos con la capacidad de manejar grandes volúmenes de datos y realizar predicciones precisas sobre el comportamiento de los clientes ante posibles incumplimientos de pagos. Estos algoritmos han sido cruciales para ayudar a las instituciones financieras a gestionar el riesgo de crédito de manera más eficiente, permitiéndoles detectar patrones de incumplimiento de manera temprana. Los algoritmos de Machine Learning más utilizados para la gestión del riesgo crediticio en el sistema financiero peruano incluyen el Árbol de Decisión, Random Forest, Support Vector Machine (SVM), Redes Neuronales, Naive Bayes, K Nearest Neighbor (KNN) y la Regresión Logística.

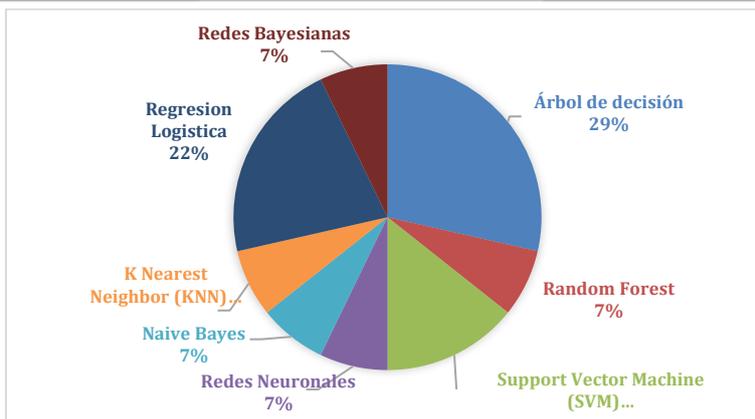


Fig 1. Algoritmos de Machine Learning usados según los trabajos obtenidos

Estos algoritmos se seleccionaron debido a su capacidad para manejar grandes volúmenes de datos, identificar patrones en los comportamientos de los clientes y realizar predicciones precisas sobre el incumplimiento de pagos o la probabilidad de que un cliente incurra en mora. El uso de estas técnicas responde a la necesidad de las instituciones financieras de mejorar la eficiencia en la evaluación y clasificación del riesgo crediticio, minimizando así las pérdidas por créditos no recuperables. En la investigación realizada por Cabanillas Romero [1], se compararon el Árbol de Decisión y la Regresión Logística, encontrando que el Árbol de Decisión era más eficaz para pronosticar el riesgo crediticio en la Coopac San José Cartavio. Por su parte, Alarcón Morales y Mora Ramos [2] destacaron el uso de Redes Bayesianas, Redes Neuronales y la Regresión Logística en su análisis de riesgo crediticio en microfinancieras peruanas, resaltando su importancia en la clasificación de clientes. En el estudio de Rayza Gómez [3], se utilizó el Árbol de Decisión y el SVM para identificar patrones de incumplimiento en una cartera castigada de créditos, destacándose estos algoritmos por su capacidad para capturar características clave de los clientes. Además, Yaranga [4] realizó un análisis comparativo entre algoritmos como SVM, Random Forest, Naive Bayes, KNN y Árbol de Decisión, siendo todos ellos útiles en diferentes contextos de predicción. Estos estudios revelan la flexibilidad y efectividad de estos algoritmos para mejorar la gestión del riesgo crediticio en el sistema financiero peruano.

Tabla1. Algoritmos de Machine Learning más utilizados según los autores

| Autor | Algoritmos Utilizados | Institución Analizada |
|-----------------------|---|--|
| Cabanillas Romero [1] | Árbol de Decisión, Regresión Logística | Coopac San José Cartavio |
| Alarcón Morales [2] | Redes Bayesianas, Redes Neuronales, Regresión Logística | Microfinancieras del Perú |
| Rayza Gómez [3] | Árbol de Decisión, SVM | Entidad Financiera (Cartera Castigada) |
| Yaranga [4] | SVM, Random Forest, Naive Bayes, KNN, Árbol de Decisión | Empresa FUTECH PERÚ S.A.C |

Nota: Datos recopilados hasta 10/10/2024

Con respecto a la segunda pregunta planteada, de acuerdo con los estudios revisados, el mejor algoritmo de Machine Learning para la gestión del riesgo crediticio en el sistema financiero peruano varía dependiendo del contexto y los datos disponibles, pero hay consenso en que ciertos algoritmos tienden a superar a otros en términos de precisión y rendimiento. El Árbol de Decisión y el Support Vector Machine (SVM) sobresalen como los más eficaces en varios estudios.

En la investigación de Cabanillas Romero [1], se concluyó que el Árbol de Decisión superó a la Regresión Logística en la predicción de riesgo crediticio. Similarmente, Rayza Gómez [3] identificó que el Árbol de Decisión fue el más preciso para identificar patrones de incumplimiento de clientes que habían sido cesados, mostrando mejor desempeño que otros algoritmos utilizados. Por otro lado, Yaranga [4] encontró que el SVM fue el algoritmo con el mayor nivel de concordancia, logrando un 99.8% de precisión en la predicción del riesgo crediticio, superando a otros modelos como el Random Forest y Naive Bayes. Finalmente, Alarcón Morales y Mora Ramos [2] subrayaron que las Redes Neuronales y Redes Bayesianas también ofrecieron resultados sólidos, aunque el SVM y el Árbol de Decisión fueron frecuentemente los que mejor desempeño mostraron.

Estos hallazgos sugieren que tanto el Árbol de Decisión como el SVM se posicionaron como los algoritmos más efectivos en la gestión del riesgo crediticio en el sistema financiero peruano, dependiendo de las características específicas de los datos y de la institución financiera en cuestión.

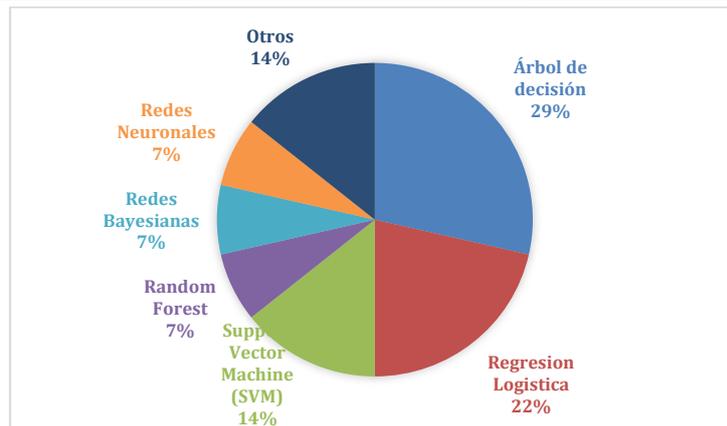


Fig 2. Mejor algoritmo de Machine Learning usados para gestión de riesgo crediticio según los trabajos obtenidos

4 Conclusiones

Los resultados obtenidos en esta investigación destacan que la elección del algoritmo de Machine Learning depende del enfoque aplicado a la gestión del riesgo crediticio, lo que permite a las instituciones financieras ajustar sus métodos a las características particulares de sus carteras de clientes. La preferencia recurrente por algoritmos como el Árbol de Decisión y Random Forest en varios estudios resalta su efectividad para identificar patrones complejos en los datos, además de su capacidad para proporcionar interpretaciones claras que facilitan la toma de decisiones.

Se descubrió que el mejor algoritmo de Machine Learning utilizado para la gestión del riesgo crediticio en el sistema financiero peruano fue el Árbol de Decisión, según varios estudios que evidencian su alta precisión y capacidad para identificar patrones de incumplimiento. Sin embargo, el modelo de Support Vector Machine (SVM) también demostró ser excepcionalmente eficaz, logrando una alta tasa de precisión y sensibilidad en diferentes contextos. Esto indica que, aunque el Árbol de Decisión es el más destacado, la elección del algoritmo óptimo puede depender de las características específicas de los datos y de los objetivos de cada institución financiera.

5 Referencias

- [1] J. Grau Álvarez y J. Portela González, «MACHINE LEARNING Y RIESGO DE CRÉDITO».
- [2] L. Rayza Gomez, «MACHINE LEARNING APLICADO A LA GESTIÓN DE RIESGOS. CASO DE UNA CARTERA CASTIGADA DE CRÉDITOS POR CONVENIOS DE UNA ENTIDAD FINANCIERA EN PERÚ», *Revista de Investigación Interdisciplinaria en Métodos Experimentales*, vol. 1, n.º 12, pp. 98-117, dic. 2023, Accedido: 9 de octubre de 2024. [En línea]. Disponible en: <https://ojs.econ.uba.ar/index.php/metodosexperimentales/article/view/3123>
- [3] J. C. Cabanillas Romero, «Eficacia de modelos Machine Learning para el pronóstico del riesgo crediticio en la cartera consumo. Coopac San José Cartavio», 2022, *Universidad Nacional de Trujillo*. Accedido: 9 de octubre de 2024. [En línea]. Disponible en: <https://hdl.handle.net/20.500.14414/16149>
- [4] I. P. Yaranga Vite, «Machine Learning para predecir el riesgo crediticio de un cliente en la Empresa FUTECH PERU S.A.C, 2022», *Repositorio Institucional - UCV*, 2022, Accedido: 9 de octubre de 2024. [En línea]. Disponible en: <https://repositorio.ucv.edu.pe/handle/20.500.12692/104048>
- [5] A. Morales, E. Manuel, M. Ramos, y B. Javier, «Modelo para la evaluación del riesgo crediticio para los clientes de las microfinancieras del Perú Item Type info:eu-repo/semantics/bachelorThesis», Accedido: 9 de octubre de 2024. [En línea]. Disponible en: <http://hdl.handle.net/10757/650407>
- [6] «Machine Learning | Qué es, tipos, ejemplos y cómo implementarlo». Accedido: 13 de octubre de 2024. [En línea]. Disponible en: <https://www.grapheverywhere.com/machine-learning-que-es-tipos-ejemplos-y-como-implementarlo/>
- [7] «7 algoritmos de machine learning que hay que conocer: Guía para principiantes | Coursera». Accedido: 13 de octubre de 2024. [En línea]. Disponible en: <https://www.coursera.org/mx/articles/machine-learning-algorithms>
- [8] N. S. Anzola, «Máquinas de soporte vectorial y redes neuronales artificiales en la predicción del movimiento USD/COP spot intradiario», *ODEON*, n.º 9, pp. 113-172, feb. 2015, doi: 10.18601/17941113.N9.04.
- [9] J. . Bessis, «Risk management in banking», 2015.
- [10] E. Profesional de Contabilidad Finanzas, R. Chambergo Yoni Bach, N. Valdivia Liz Micaela Asesor, y M. Vila Flores Javier, «UNIVERSIDAD PERUANA LOS ANDES Facultad de Ciencias Administrativas y Contables Para Optar : El Título Profesional de Contador Público Autor(es)», 2023.