

Daniela Herrera Arbeláez, Edy Soralla Bedoya Ríos (2023).

Construcción de un modelo para predecir la morosidad de cartera. *Cuaderno Activa*, 15, 39-47.



# Construcción de un modelo para predecir la morosidad de cartera

*Building a model to predict portfolio delinquency*

Daniela Herrera Arbeláez <sup>1</sup>, Edy Soralla Bedoya Ríos <sup>2</sup>

**Tipo de Artículo:** Investigación.

**Recibido:** 23/11/2022 **Aprobado:** 14/07/2023 **Publicado:** 22/12/2023

**Resumen:** Existe una real e importante necesidad en el sistema financiero, principalmente en Colombia, de aplicar este tipo de modelos de predicción de morosidad, pues, si bien las entidades realizan una recolección de datos y existe una operación humana involucrada en el análisis de otorgamientos, hace falta una herramienta que permita tener una visión más profunda del análisis de los registros y una evaluación que permita tomar decisiones confiables. Si bien, siempre va a existir un riesgo y en muchas ocasiones la morosidad se va a presentar, es valioso poder reducir la misma con base en un modelo que realice una evaluación a priori. Adicional a la necesidad, se encuentra que existen diversas técnicas que suelen ser utilizadas para este tipo de modelos predictivos, tales como Regresión logística, redes neuronales, árboles de decisión. Las cuales contando con un conjunto de datos actualizados y verídicos arrojan resultados

muy confiables que contribuyen a buenas prácticas de manejo del sector financiero y una clasificación adecuada de los clientes, tanto nuevos como los existentes, que requieren un nuevo otorgamiento crediticio.

**Palabras clave:** Crédito; riesgo; mora; retraso.

**Abstract:** There is a real and important need in the financial system, mainly in Colombia, to apply this type of default prediction models, because although the bank companies collect data and there is a human operation involved in the analysis of credit granting a tool is needed that allows a deeper vision of the analysis of the records and an evaluation that allows reliable decisions to be made. Although there will always be a risk and on many times, a late payment will happen it is very important to be able to reduce it based on a model

1 Autor correspondiente: Daniela Herrera Arbeláez. Mayor título: Profesional en negocios internacionales. Filiación institucional: Universidad Católica Luis Amigó. País: Colombia, Ciudad: Medellín. Correo electrónico: daniela.herrerabe@amigo.edu.co. ORCID: <https://orcid.org/0000-0002-9465-443X>

2 Autor correspondiente: Edy Soralla Bedoya Ríos. Mayor título: Profesional en administración de empresas. Filiación institucional: Universidad Católica Luis Amigó. País: Colombia, Ciudad: Medellín. Correo electrónico: edy.bedoyari@amigo.edu.co. ORCID: <https://orcid.org/0000-0002-1263-5711>

that performs an a priori evaluation. In addition to the need, it is found that there are several techniques that are usually used for this type of predictive models such as logistic regression, neural networks, decision trees, which, having a set of updated and true data, give very reliable results that help to good management practices in the financial sector and a good classification of both new and existing clients that require a new credit granting.

**Keywords:** Credit; risk; default; delay.

## I. Introducción

La falta de conocimiento detallado que presenta la entidad de servicios financieros acerca del nivel de riesgo que existe al momento del otorgamiento de crédito y desconocimiento de la probabilidad de que sus deudores falten en el pago de sus cuotas. La necesidad de establecer un modelo que permita conocer este nivel de riesgo y, así mismo, poder realizar un cuidado riguroso a su flujo de caja y manejo de cartera.

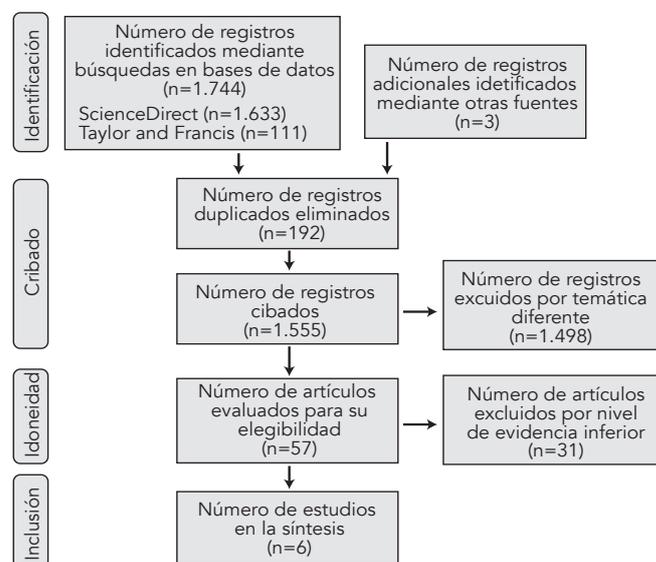
Conocer el comportamiento de pago de los deudores en el mercado financiero e identificar las

principales causas que inciden en el incumplimiento de los pagos. Adicionalmente, conocer cómo se ha empleado el *big data* y *machine learning* y qué técnicas se han utilizado para predecir la morosidad de cartera.

## II. Métodos

Identificar el problema de negocio y definir conceptos o términos técnicos requeridos para el entendimiento de la investigación. Para iniciar la revisión sistemática de literatura, definir palabras clave y cadenas o ecuaciones de búsqueda con operadores booleanos, definir bases de datos que se emplearán para realizar la búsqueda, almacenar las fechas del período de búsqueda y el total de artículos encontrados por cada ecuación de búsqueda, proceder con la selección de artículos almacenando criterios de inclusión y exclusión para realizar flujograma prisma y plasmar los resultados del proceso de selección. Posteriormente, realizar análisis de los artículos seleccionados para discusión y conclusión de cada una de las preguntas de investigación planteadas y conclusión general. Para finalizar, la bibliografía debidamente referenciada con las normas IEEE.

**Figura 1.** Flujograma Prisma



Nota: Fuente elaboración propia [1].

### III. Resultados

La recolección y tratamiento adecuado de los datos es una herramienta muy valiosa hoy en día, la cual no es indiferente en el momento de los estudios de crédito, pues esta se puede encontrar directamente relacionada con la calidad de las carteras de créditos bancarios. Estimar correctamente los riesgos y contar con información altamente inequívoca es de vital importancia, previo al otorgamiento de un crédito [1].

No solo es importante conocer los factores que inciden en la morosidad, sino que las entidades financieras conozcan y entiendan la importancia que tiene el predecir el riesgo de la misma, pues el desconocer esta información puede ocasionar un deterioro en su capital y el de sus accionistas, tanto como una afectación a su imagen, pues podrían hacerse ver en el mercado como una entidad negligente, si su valor decrece a causa de las pérdidas excesivas generadas por las moras de sus prestatarios [2].

Los burós de crédito, son instituciones que almacenan y entregan información sobre el comportamiento crediticio de los deudores. El intercambio de información entre las entidades de servicios financieros y los burós de crédito, motiva a los deudores a realizar el pago oportuno de sus obligaciones financieras, con el fin de evitar ser incluidos en las listas negras de los registros [3].

El modelo de calificación crediticia estima un puntaje crediticio haciendo uso del hábito de pagos, deuda vigente y plazo, tipos de crédito otorgados, información demográfica y de comportamiento. Posterior a la estimación de puntuaciones de riesgo crediticio, se procede a comparar con otros valores preestablecidos y se ubican en grupos de acuerdo con el nivel de riesgo, para los grupos de mayor riesgo es posible que se les niegue nuevos créditos o que se realice un estudio de crédito mucho más detallado [4].

Las pérdidas económicas que generan el incumplimiento en los pagos de los créditos, dependen, en gran medida, de la gestión de las entidades de servicios financieros, teniendo en cuenta aspectos como el grado de cobertura de la tasa de interés, la provisión y el estudio cuidadoso para el otorgamiento del crédito [5].

De acuerdo con estudio realizado a una muestra de estudiantes universitarios chilenos, se identifica que los principales factores que influyen en el endeudamiento de los jóvenes, son el consumismo, la baja capacidad de postergar la gratificación, la edad, el desconocimiento en temas financieros y la educación. Por otra parte, se encuentran diferencias de género, siendo los hombres quienes muestran mayor actitud favorable hacia la deuda [6].

Hace algunos años, la administración del riesgo crediticio se realizaba solo con la experiencia del analista de crédito. Ahora, existen múltiples métodos para predecir la probabilidad de incumplimiento; entre estos están los modelos de *scoring*, que clasifican a los solicitantes por nivel de riesgo con base a la información suministrada en la solicitud del crédito y el comportamiento histórico de pagos [7].

El efecto “manada del consumidor” también se traduce en un riesgo de incumplimiento de pago de parte de los deudores; en este fenómeno los consumidores lo que hacen es imitar a otros por razones de seguridad financiera, es decir, seguir a la multitud, generando así morosidades al sistema financiero, dado a una falta de pago generalizada. Para predecir este tipo de riesgo se debe revisar realizar una regresión de riesgos reales; este es un análisis diferente, pues está más basado en las condiciones generales del mercado, pero, al tenerlo en cuenta, las entidades pueden predecir el riesgo de incumplimiento en las transacciones de crédito [8].

Está demostrado que las entidades financieras capaces de realizar una evaluación de crédito adecuada tienen un menor riesgo de presentar pérdidas en caso de una crisis financiera ocasionada por morosidad en carteras; esto, por lo general, pueden realizarlo las entidades de mayor tamaño que invierten recursos para este análisis, quedando así en un nivel de riesgo mayor las entidades que realizan una evaluación crediticia inadecuada [9].

Existen múltiples motivos por los cuales los clientes pueden faltar en sus pagos; por tanto, evaluar el otorgamiento de un crédito también implica, por ende, evaluar la probabilidad de incumplimiento se debe revisar algunos factores como su puntaje, tipos de créditos tomados antes, historial de pagos, deudas actuales. Para este análisis se propone también llevar a cabo una evaluación regulatoria con el fin de clasificar entre clientes buenos y clientes malos [4].

Además de pensar en un modelo que permita conocer y mitigar los riesgos de morosidad es importante contar con información financiera veraz que permita realizar un análisis que respalde las decisiones de otorgamientos crediticios y es allí donde la recolección de datos que se conviertan en información fiable es un factor importante [10].

El *Big Data* se ha venido implementado de varias maneras en el sector bancario; una de ellas es a través de probabilidad de incumplimiento (PD), la cual es una métrica utilizada en la modelización de riesgos y determina la probabilidad de incumplimiento de parte de los prestatarios en un determinado tiempo; este tipo de herramientas desde hace unos años son un complemento para este tipo de transacciones.

financieras, buscando que estas sean un apoyo a la operación humana que interviene en la aprobación de un crédito [11].

Los modelos de redes neuronales se han convertido en una herramienta poderosa, dada la capacidad de las mismas para el modelado de interacciones; en uno de los estudios se desarrolló un modelo basado en correlaciones, el cual posteriormente es evaluado por medio de transacciones reales arrojando esto una serie de datos predictivos valiosos para el análisis de riesgo [12].

Siempre pueden existir nuevos enfoques de modelos para la predicción de riesgos crediticios, como en este caso, donde se presenta un modelo de árbol de decisión utilizando la relación de ganancias y, posterior, agrupando la información; esto, con el fin de entregar a los gerentes de banca un modelo "híbrido" que posea información altamente confiable para la evaluación de sus clientes [13].

Para el estudio de riesgo crediticio, el *Big Data* es parte fundamental, como se demuestra en esta investigación realizada en México, donde se tuvo en cuenta una muestra de más de 43.000 cuentas y, a partir de los datos históricos, se analizaron variables como cumplimiento / Incumplimiento, número de impagos, historial de pagos, meses transcurridos del crédito, límite de crédito, saldo. A partir de estos datos, se aplicaron diferentes métodos con el fin de realizar predicciones valiosas que aporten a minimizar el riesgo de pérdidas en la organización [7].

Hoy en día, se producen y almacenan altos volúmenes de datos no estructurados, como correos electrónicos, llamadas telefónicas, datos de texto, imágenes y transacciones bancarias. Estos datos son de gran utilidad para la predicción del incumplimiento en los pagos de los créditos, pero siguen sin utilizarse porque requieren de un procesamiento previo para luego poder aplicar las técnicas estándar de predicción. Hay estudios más recientes, que usan el aprendizaje automático y lo combinan con frecuencias de términos para explotar esta información para las predicciones de riesgo crediticio [14].

Las muestras pequeñas o con datos faltantes pueden llevar a predicciones con poca precisión, es por esto que la generación y almacenamiento de datos que, normalmente, provienen de información contable y bases de datos transaccionales, pueden ayudar a los algoritmos de análisis y a mejorar el modelo de evaluación de riesgos [15].

La mayoría de riesgos crediticios emplean decisiones tradicionales binarias de aceptación o rechazo, pero, en ocasiones, la información con la que se cuenta es imprecisa para tomar dicha decisión. Para una mejor calidad de los estudios de crédito, se requieren decisiones de 3 vías, con el fin de decidir de inmediato aprobaciones o rechazos y, para los casos restantes, capturar información adicional que proporcione una nueva perspectiva para evaluaciones de crédito más detallada que aporten a una decisión acertada [16].

La cuarta revolución industrial ha representado grandes mejoras para el sector financiero. El aprendizaje automático genera modelos que explican más claramente los datos, permitiendo mejores evaluaciones para la toma de decisiones. Es una gran decisión determinar el modelo óptimo para las calificaciones crediticias, porque este puede afectar otros aspectos financieros como la estructura de capital, la liquidez de acciones, fijación de precios y diversificación empresarial [17].

Se realizó un estudio para identificar mecanismos de predicción de morosidad en el programa de financiación de vivienda para población de bajos ingresos en Brasil, llamado "Mi casa, mi vida". Teniendo en cuenta que es población con pocos ingresos y, por lo tanto, muy propensos al impago, después de evaluar diferentes métodos, los resultados muestran, principalmente, que la elección del método apropiado podría reducir en gran medida el índice de morosidad y los costos por clasificación errónea. Adicionalmente, con el fin de evitar criterios subjetivos, se eliminaron variables discriminatorias como género, edad y estado civil, y se encontró que el poder discriminatorio de la calificación de riesgo se conserva [18].

Asegurar que no existirá pérdida en el ejercicio de créditos bancarios es imposible de predecir; sin embargo, por medio del uso del *Big Data* y las herramientas, tales como modelos predictivos, modelos estadísticos, regresión logística o redes neuronales artificiales, se puede medir el nivel de riesgo de pérdida para las entidades financieras y las probabilidades de que un prestatario incumpla en realizar sus pagos. Sin embargo, el riesgo no puede predecirse al 100%, ya que es difícil determinar factores externos como crisis financieras que se presenten de manera inesperada, que no pueden capturarse por medio de los modelos generados a través del *Big Data* [2].

Una de las técnicas más valiosas para predecir la morosidad es contar con acceso a los historiales crediticios de los prestatarios, pues, de esta manera, los bancos pueden evaluar con mayor precisión la solvencia de sus usuarios y, así mismo, tomar decisiones más informadas sobre la concesión de préstamos y establecer tasas de interés justas, acordes a la capacidad de endeudamiento y pago de sus clientes. Cuando el grado de divulgación y manejo de la información crediticia es alto, el poder predictivo de los modelos de calificación también es alto, ocurre que los riesgos crediticios se reducen [1].

El riesgo financiero de falta de pago de parte de los prestatarios es un factor que siempre existirá en las transacciones de crédito; por esto, los expertos lo han abordado desde varias formas; una de ellas es comparándolo como el modelo epidemiológico Susceptible-Infectado-Recuperado (SIR), pues, de cierta forma, el riesgo financiero funciona como un virus, donde una crisis puede iniciar y propagarse rápidamente en todo el sector dejando afectaciones, pues los bancos no son inmunes y, por el contrario, siempre existe una tasa de infección que solo puede mitigarse con lo fortalecida que esté la estructura de su red; en ese caso, que tan rigurosa sea la supervisión financiera [19].

Una de las técnicas que ha sido aplicada para la medición de riesgo crediticio, son técnicas de aprendizaje automático; ha sido adoptada por el área financiera, dado que, por medio de los algoritmos aplicados, se ha llegado a resultados óptimos; sin embargo, también se hace énfasis en la importancia que tiene para el rendimiento de estos modelos que los datos recolectados sean de alta calidad [20].

Utilizar un modelo para predecir el riesgo de morosidad no se realiza solo para nuevos clientes; también, por medio de la técnica de regresión logística, se puede determinar, con base en los datos que ya se cuenta de clientes existentes, la probabilidad de que estos incumplan con sus pagos en un nuevo crédito a otorgar y, así, la entidad tendría herramientas para brindar o no una nueva concesión [21].

Contar con un modelo para predecir riesgo es demasiado importante, pero también lo es el realizar una clasificación adecuada de la información a utilizar antes de realizar un entrenamiento de los datos; por ello, previamente se debe realizar la transformación de estos y asegurarse de que los registros con que se cuenta son los necesarios; de lo contrario, los modelos pueden fallar por un problema de clasificación [22].

A medida que la economía global crece, también lo hacen los riesgos financieros; es por este motivo que el *Big Data* empezó a jugar un papel importante en este sector. A través de los avances en tecnología se ha evolucionado en el concepto de análisis de crédito, buscando generar un impacto positivo a través de la evolución de las herramientas en la evaluación de estos [23].

El extenso volumen de datos manejado por las entidades bancarias hoy en día obliga a que sean utilizadas herramientas relacionadas al *Big Data*, capaces de generar algoritmos que produzcan información rápida e imparcial y, por

ende, sea posible tomar mejores decisiones al momento de realizar los análisis confiables de información financiera [24].

La SVR o regresión de Vectores de soporte es una de las técnicas más utilizadas para predicción de series temporales; esto, dado a que permite un mapeo flexible de la información, lo cual es muy importante al momento de analizar grandes cantidades de datos, como es el caso de una entidad financiera que busque evaluar sus créditos por medio de estas herramientas [25].

Las entidades financieras recopilan información al momento de cualquier solicitud de crédito; así mismo, al momento de un nuevo otorgamiento de préstamo obtienen información en ese momento y durante la vigencia del mismo generando así registros que permiten apoyar la venta cruzada de nuevos productos, apoyando así el área de mercadeo, pues con estos registros recopilados ya se cuenta con información predictiva respecto al comportamiento de pago del cliente [26].

#### IV. Conclusiones

Algunos de los principales factores que influyen en la morosidad de cartera en cuanto al comportamiento del deudor, son el consumismo y la falta de educación financiera. Por otra parte, los estudios demuestran que un correcto y detallado estudio de crédito, la provisión, los históricos de datos como hábito de pago, créditos otorgados, información demográfica y de comportamiento, y la aplicación de un adecuado modelo predictivo de riesgo crediticio, inciden en la disminución del índice de morosidad y, por consiguiente, la disminución de pérdidas financieras.

La captación y almacenamiento de históricos de información financiera veraz son determinantes para la aplicación de modelos que permitan hallar probabilidades de incumplimiento en los pagos. Entre más robusta la información, mucho mejor, ya que, con muestras pequeñas, los modelos

pueden carecer de precisión. Adicionalmente, en los datos no estructurados, se encuentra información muy valiosa que, al procesarla, podría generar grandes aportes a los modelos. Todo lo anterior sirve de herramientas de apoyo para la operación humana, aportando agilidad, precisión y disminución de riesgos.

El alto volumen de datos ha obligado a las entidades de servicios financieros a utilizar herramientas de Big Data con el fin de generar información ágil e imparcial que permita tomar decisiones asertivas. Entre las principales técnicas utilizadas para los modelos de riesgo crediticio y probabilidades de incumplimiento en los pagos,

están la regresión logística, redes neuronales, árboles de decisión y aprendizaje automático; la elección del modelo podría depender de los datos que se tienen, las variables a analizar y el tipo de estudio requerido de acuerdo con la necesidad del negocio. En todo caso, para cualquier técnica, es imprescindible que los datos recolectados sean de alta calidad, que se tenga la información de las variables requeridas para estudio, que haya un alto manejo de la información crediticia y entendimiento de los datos y que se realice una adecuada clasificación de la información para el entrenamiento de los datos; esto facilita el rendimiento y la precisión de los modelos.

## V. Referencias

- [1] I. Iakimenko, M. Semenova, and E. Zimin, "The more the better? Information sharing and credit risk", *Journal of International Financial Markets, Institutions and Money*, vol. 80, p. 101651, 2022. [En línea]. Disponible en: doi: 10.1016/J.INTFIN.2022.101651.
- [2] P. Piccoli, "Valuating consumer credit portfolios", *Latin American Journal of Central Banking*, vol. 3, n° 3, p. 100067, 2022. [En línea]. Disponible en: doi: 10.1016/J.LATCB.2022.100067.
- [3] M. S. ben Ali, "Credit bureaus, corruption and banking stability", *Economic Systems*, vol. 46, n° 3, p. 100989, 2022. [En línea]. Disponible en: doi: 10.1016/J.ECOSYS.2022.100989.
- [4] M. R. Machado and S. Karray, "Assessing credit risk of commercial customers using hybrid machinelearning algorithms", *Expert Syst Appl*, vol. 200, p.116889, 2022. [En línea]. Disponible en: doi: 10.1016/J.ESWA.2022.116889.
- [5] F. E. S. Villano, "Cuantificación del riesgo de incumplimiento en créditos de libre inversión: un ejercicio econométrico para una entidad bancaria del municipio de Popayán, Colombia", *Estudios Gerenciales*, vol. 29, n° 129, pp. 416-427, 2013. [En línea]. Disponible en: doi: 10.1016/J.ESTGER.2013.11.007.
- [6] L. Mansilla Chiguay, M. Denegri Coria, and B. Álvarez Escobar, "Relación entre actitudes hacia el endeudamiento y locus de control del consumidor en estudiantes universitarios", *Suma Psicológica*, vol. 23, n° 1, pp. 1-9, 2016. [En línea]. Disponible en: doi: 10.1016/J.SUMPSI.2015.11.002.
- [7] J. C. Trejo García, M. Á. Martínez García, and F. Venegas Martínez, "Administración del riesgo crediticio al menudeo en México: una mejora econométrica en la selección de variables y cambios en sus características", *Contaduría y Administración*, vol. 62, n° 2, pp. 377-398, 2017. [En línea]. Disponible en: doi: 10.1016/j.cya.2017.01.003.
- [8] L. Wu, "The study on risk avoidance of transaction default based on the herding effect", *Systems Science & Control Engineering*, vol. 9, n° 1, pp. 602-611, 2021. [En línea]. Disponible en: doi: 10.1080/21642583.2021.1975320.
- [9] M. Naili and Y. Lahrichi, "Banks' credit risk, systematic determinants and specific factors: recent evidence from emerging markets", *Heliyon*, vol. 8, n° 2, p. e08960, 2022. [En línea]. Disponible en: doi: 10.1016/j.heliyon.2022.e08960.
- [10] K. Zheng et al., "Blockchain technology for enterprise credit information sharing in supply chain finance", *Journal of Innovation & Knowledge*, vol. 7, n° 4, p. 100256, 2022. [En línea]. Disponible en: doi: 10.1016/J.JIK.2022.100256.
- [11] L. Coenen, W. Verbeke, and T. Guns, "Machine learning methods for short-term probability of default: A comparison of classification, regression and ranking methods", *Journal of the Operational Research Society*, vol. 73, n° 1, pp. 191-206, 2022. [En línea]. Disponible en: doi: 10.1080/01605682.2020.1865847.
- [12] P. Giudici, B. Hadji-Misheva, and A. Spelta, "Quality Engineering Network based credit risk models", 2019. [En línea]. Disponible en: doi:10.1080/08982112.2019.1655159.
- [13] C.-H. Weng, & Cheng, and K. Huang, "Applied Artificial Intelligence A Hybrid Machine Learning Model for Credit Approval", *Applied Artificial Intelligence*, vol. 35, pp. 1439-1465, 2021. [En línea]. Disponible en: doi: 10.1080/08839514.2021.1982475.
- [14] J. Kriebel and L. Stitz, "Credit default prediction from user-generated text in peer-to-peer lending using deep learning", *Eur J Oper Res*, vol. 302, n° 1, pp. 309-323, 2022. [En línea]. Disponible en: doi: 10.1016/J.EJOR.2021.12.024.

- [15] X. Fan, X. Guo, Q. Chen, Y. Chen, T. Wang, and Y. Zhang, "Data augmentation of credit default swap transactions based on a sequence GAN", *InfProcess Manag*, vol. 59, no. 3, p. 102889, 2022. [En línea]. Disponible en: doi: 10.1016/J.IPM.2022.102889.
- [16] F. Shen, X. Zhang, R. Wang, D. Lan, and W. Zhou, "Sequential optimization three-way decision model with information gain for credit default risk evaluation", *Int J Forecast*, vol. 38, n° 3, pp. 1116-1128, 2022. [En línea]. Disponible en: doi: 10.1016/J.IJFORECAST.2021.12.011.
- [17] J. P. Li, N. Mirza, B. Rahat, and D. Xiong, "Machine learning and credit ratings prediction in the age of fourth industrial revolution", *Technol Forecast Soc Change*, vol. 161, p. 120309, 2020. [En línea]. Disponible en: doi: 10.1016/J.TECHFORE.2020.120309.
- [18] 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*, vol. 83, p. 105640, 2019. [En línea]. Disponible en: doi:10.1016/j.asoc.2019.105640.
- [19] B. Chenyu, Y. Haomiao, and Z. Ning, "How does the supervision stringency affect systemic risk based on the differential dynamic model?", *Systems Science & Control Engineering*, vol. 7, n° 1, pp. 357-368, 2019. [En línea]. Disponible en: doi: 10.1080/21642583.2019.1681031.
- [20] Z. Hassani, A. Meybodi, and V. Hajhashemi, "Credit Risk Assessment Using Learning Algorithms for Feature Selection," *Fuzzy Information and Engineering*, vol. 12, n° 4, pp. 529-544, 2021. [En línea]. Disponible en: doi: 10.1080/16168658.2021.1925021.
- [21] P. Giudici, B. Hadji-Misheva, and A. Spelta, "Network based credit risk models", *Qual Eng*, vol. 32, n° 2, pp. 199-211, 2020. [En línea]. Disponible en: doi: 10.1080/08982112.2019.1655159.
- [22] A. Abdullah and A. Barnawi, "A Novel Crossing Minimization Ranking Method", *Applied Artificial Intelligence*, vol. 29, n° 1, pp. 66-99, 2015. [En línea]. Disponible en: doi: 10.1080/08839514.2015.983014.
- [23] G. Du, Z. Liu, and H. Lu, "Application of innovative risk early warning mode under big data technology in Internet credit financial risk assessment", *J Comput Appl Math*, vol. 386, p. 113260, 2021. [En línea]. Disponible en: doi: 10.1016/J.CAM.2020.113260.
- [24] A. Pérez-Martín, A. Pérez-Torregrosa, and M. Vaca, "Big Data techniques to measure credit banking risk in home equity loans", *J Bus Res*, vol. 89, pp. 448-454, 2018. [En línea]. Disponible en: doi: 10.1016/J.JBUSRES.2018.02.008.
- [25] T. Law and J. Shawe-Taylor, "Practical Bayesian support vector regression for financial time series prediction and market condition change detection", *Quant Finance*, vol. 17, n° 9, pp. 1403-1416, 2017. [En línea]. Disponible en: doi: 10.1080/14697688.2016.1267868.
- [26] R. A. Mancisidor, M. Kampffmeyer, K. Aas, and R. Jenssen, "Generating customer's credit behavior with deep generative models", *Knowl Based Syst*, vol. 245, p. 108568, 2022. [En línea]. Disponible en: doi:10.1016/J.KNOSYS.2022.108568.