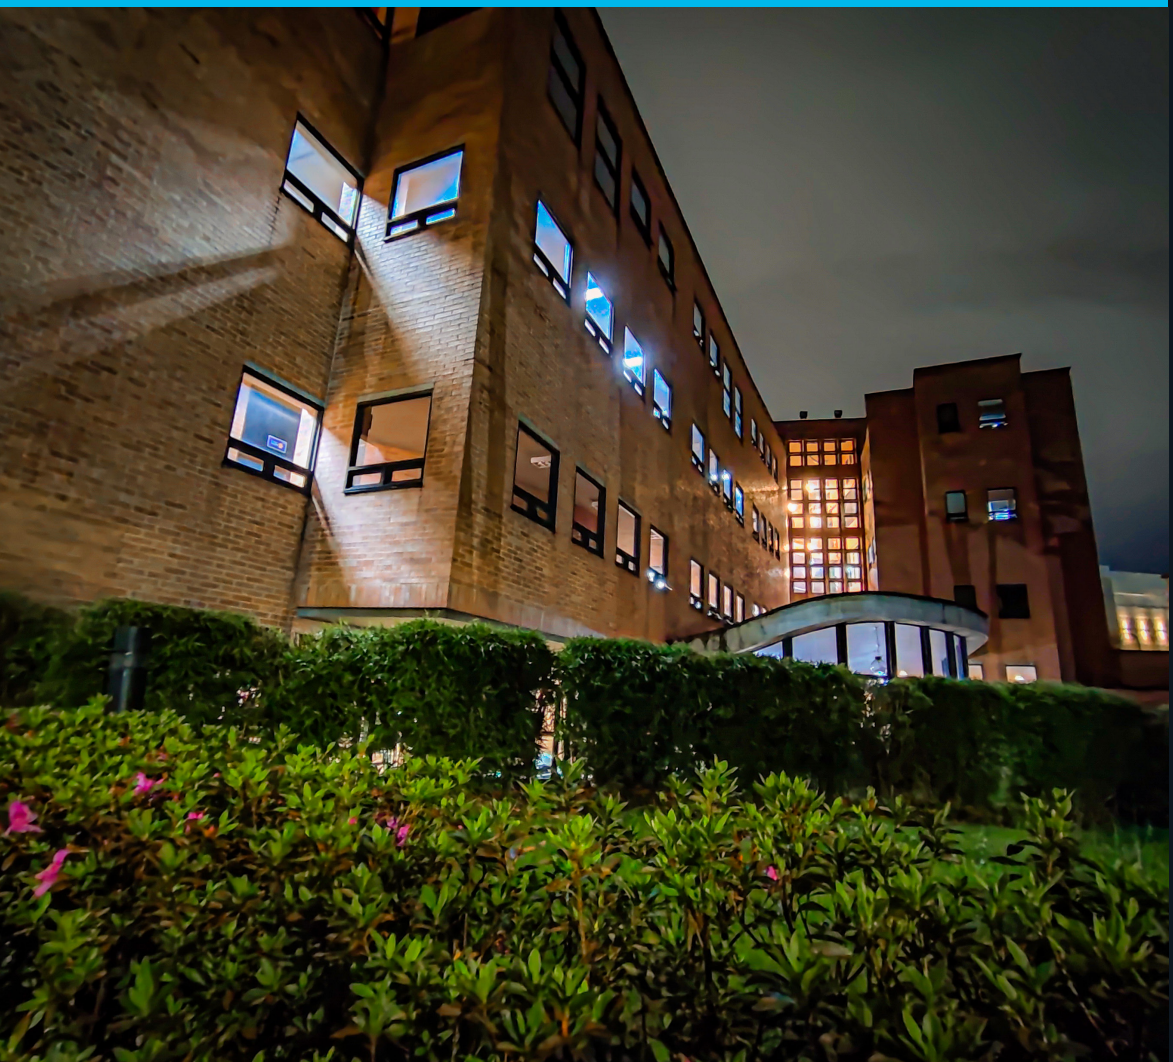




CUADERNOS DE ECONOMÍA

ISSN 0121-4772



Facultad de Ciencias Económicas
Escuela de Economía
Sede Bogotá



UNIVERSIDAD
NACIONAL
DE COLOMBIA

ASESORES EXTERNOS

COMITÉ CIENTÍFICO

Ernesto Cárdenas
Pontificia Universidad Javeriana-Cali

José Félix Cataño
Universidad de los Andes

Philippe De Lombaerde
NEOMA Business School y UNU-CRIS

Edith Klimovsky
Universidad Autónoma Metropolitana de México

José Manuel Menudo
Universidad Pablo de Olavide

Gabriel Misas
Universidad Nacional de Colombia

Mauricio Pérez Salazar
Universidad Externado de Colombia

Fábio Waltenberg
Universidade Federal Fluminense de Rio de Janeiro

EQUIPO EDITORIAL

Daniela Cárdenas
Karen Tatiana Rodríguez

William David Malaver
Estudiante auxiliar

Proceditor Ltda.
Corrección de estilo, armada electrónica,
finalización de arte, impresión y acabados
Tel. 757 9200, Bogotá D. C.

Luis Tarapuez - Equipo de comunicaciones FCE
Fotografía de la cubierta

Indexación, resúmenes o referencias en

SCOPUS

Thomson Reuters Web of Science
(antiguo ISI)-SciELO Citation Index

ESCI (Emerging Sources Citation Index) - Clarivate Analytics

EBSCO

PubIndex - Categoría B - Colciencias

SciELO Social Sciences - Brasil

RePEc - Research Papers in Economics

SSRN - Social Sciences Research Network

EconLit - Journal of Economic Literature

IBSS - International Bibliography of the Social Sciences

PAIS International - CSA Public Affairs Information Service

CLASE - Citas Latinoamericanas en Ciencias Sociales y Humanidades

Latindex - Sistema regional de información en línea

HLAS - Handbook of Latin American Studies

DOAJ - Directory of Open Access Journals

CAPEs - Portal Brasileiro de Informação Científica

CIBERA - Biblioteca Virtual Iberoamericana España / Portugal

DIALNET - Hemeroteca Virtual

Ulrich's Directory

DOTEC - Documentos Técnicos en Economía - Colombia

LatAm-Studies - Estudios Latinoamericanos

Redalyc

Universidad Nacional de Colombia

Carrera 30 No. 45-03, Edificio 310, primer piso
Correo electrónico: revcuaco_bog@unal.edu.co

Página web: www.ceconomia.unal.edu.co

Teléfono: (571)3165000 ext. 12308, AA. 055051, Bogotá D. C., Colombia

Cuadernos de Economía Vol. 45 No. 97 - 2026

El material de esta revista puede ser reproducido citando la fuente. El contenido de los artículos es responsabilidad de sus autores y no compromete de ninguna manera a la Escuela de Economía, ni a la Facultad de Ciencias Económicas, ni a la Universidad Nacional de Colombia.

UNIVERSIDAD NACIONAL DE COLOMBIA

Rector

José Ismael Peña Reyes

Vicerrectora Sede Bogotá
Olivia Lorena Chaparro Díaz

FACULTAD DE CIENCIAS ECONÓMICAS

Decana

Liliana Alejandra Chicaiza Becerra

ESCUELA DE ECONOMÍA

Director

Óscar Arturo Benavidez González

VICEDECANATURA DE INVESTIGACIÓN Y EXTENSIÓN

Hernando Bayona Rodríguez

CENTRO DE INVESTIGACIONES PARA EL DESARROLLO - CID

Carlos Osorio Ramírez

DOCTORADO Y MAestrÍA EN CIENCIAS ECONÓMICAS Y PROGRAMA CURRICULAR DE ECONOMÍA

Coordinador

Mario García Molina

CUADERNOS DE ECONOMÍA

EDITOR

Jonathan Daniel Gómez Zapata
Universidad Nacional de Colombia

CONSEJO EDITORIAL

Liliana Chicaiza

Universidad Nacional de Colombia

Juan Miguel Gallego

Universidad del Rosario

Mario García Molina

Universidad Nacional de Colombia

Iván Hernández

Universidad de Ibagué

Paula Herrera Idárraga

Pontificia Universidad Javeriana

Noemí Levy

Universidad Nacional Autónoma de México

Iván Montoya

Universidad Nacional de Colombia, Medellín

Juan Carlos Moreno Bríd

Universidad Nacional Autónoma de México

Manuel Muñoz Conde

Universidad Nacional de Colombia

Esteban Pérez Caldentey

Universidad de Pittsburgh

Matías Vernengo

Bucknell University

Marta Juanita Villaveces

Universidad Nacional de Colombia

Esta obra está bajo una Licencia Creative Commons Atribución-NoComercial-SinDerivadas 2.5 Colombia.

Usted es libre de:

Compartir - copiar, distribuir, ejecutar y comunicar públicamente la obra

Bajo las condiciones siguientes:

- **Atribución** — Debe reconocer los créditos de la obra de la manera especificada por el autor o el licenciante. Si utiliza parte o la totalidad de esta investigación tiene que especificar la fuente.
- **No Comercial** — No puede utilizar esta obra para fines comerciales.
- **Sin Obras Derivadas** — No se puede alterar, transformar o generar una obra derivada a partir de esta obra.

Los derechos derivados de usos legítimos u otras limitaciones reconocidas por la ley no se ven afectados por lo anterior.



El contenido de los artículos y reseñas publicadas es responsabilidad de los autores y no refleja el punto de vista u opinión de la Escuela de Economía de la Facultad de Ciencias Económicas o de la Universidad Nacional de Colombia.

The content of all published articles and reviews does not reflect the official opinion of the Faculty of Economic Sciences at the School of Economics, or those of the Universidad Nacional de Colombia. Responsibility for the information and views expressed in the articles and reviews lies entirely with the author(s).

MODELACIÓN DEL *SCORING* DE CRÉDITO: UNA REVISIÓN SISTEMÁTICA DE LITERATURA DE SUS DETERMINANTES PSICOLÓGICOS

Jhon Alvaro Pérez Cruz
Claudia Milena Pico Bonilla,
Suelen Emilia Castiblanco Moreno

Pérez Cruz, J. A., Pico Bonilla, C. M., & Castiblanco Moreno, S. E. (2026). Modelación del *scoring* de crédito: una revisión sistemática de literatura de sus determinantes psicológicos. *Cuadernos de Economía*, 45(97), 359-381.

Los *scoring* de crédito se han calculado tradicionalmente a partir de información sociodemográfica y crediticia contenida en las bases de datos de las entidades financieras. Tras las recomendaciones del Comité de Basilea en 2004 y la crisis de 2008, se evidenció la falta de actualización de los modelos y la existencia de asimetrías de información. En esta revisión sistemática de 30 artículos sobre factores

J. Á. Pérez Cruz

Universidad de La Salle, Bogotá (Colombia). Correo electrónico: jhon.perez.cruz@gmail.com

C. M. Pico Bonilla

Universidad Militar Nueva Granada, Bogotá (Colombia). Correo electrónico: claudia.pico@unimilitar.edu.co

S. E. Castiblanco Moreno

Corporación Universitaria Asturias, Bogotá (Colombia). Correo electrónico: suelen.castiblanco@asturias.edu.co

Sugerencia de citación: Pérez Cruz, J. A., Pico Bonilla, C. M., & Castiblanco Moreno, S. E. (2026). Modelación del *scoring* de crédito: una revisión sistemática de literatura de sus determinantes psicológicos. *Cuadernos de Economía*, 45(97), 359-381. <https://doi.org/10.15446/cuad.econ.v45n97.111765>

Este artículo fue recibido el 26 de octubre 2023, ajustado el 7 de noviembre de 2024 y su publicación aprobada el 14 de noviembre de 2024.

psicológicos y su relación con el riesgo de crédito, se evidencia la falta de consenso sobre el *default*, siendo sus principales predictores psicológicos la inteligencia y los rasgos *big five* (BF), entre otros.

Palabras clave: *scoring*; crédito; determinantes psicológicos.

JEL: D14, C91, D21.

Pérez Cruz, J. Á., Pico Bonilla, C. M., & Castiblanco Moreno, S. E. (2026). Credit scoring modelling: A systematic review of literature of its psychological determinants. *Cuadernos de Economía*, 45(97), 359-381.

Credit scores have traditionally been calculated from sociodemographic and credit information contained in the databases of financial entities. After the recommendations of the Basel committee in 2004 and the 2008 crisis, the lack of updating of the models and the existence of information asymmetries became evident. In the present systematic review of 30 articles on psychological factors and their relationship with credit risk, the lack of consensus on default is evident and its main psychological predictors are intelligence and the big five traits, among others.

Keywords: Scoring; credit; psychological determinants.

JEL: D14, C91, D21.

INTRODUCCIÓN

En la teoría económica, el crédito se considera un mecanismo de transmisión del ahorro a la inversión que surge por la existencia de agentes excedentarios y deficitarios. El crédito permite intercambiar el consumo futuro por presente y habilita a personas y empresas para disfrutar de bienes de capital o consumo antes de ahorrar para obtenerlos en el futuro (Parkin y Loría Díaz, 2010), así como a los Gobiernos financiar el gasto y la inversión (Keynes, 2014), y a los bancos centrales establecer políticas monetarias (Friedman, 1959; Minsky y Kaufman, 2008).

En cuanto a los créditos otorgados a los individuos, desde mediados del siglo XX, cuando se desarrolla el análisis formal para otorgarlos (Ferreira *et al.*, 2019), los prestamistas han valorado el riesgo crediticio mediante la evaluación de las denominadas 5 C del análisis de crédito: capacidad de pago, capital de respaldo, colateral o garantía, contexto económico y carácter de pago de los solicitantes (Morales Castro y Morales Castro, 2015).

El carácter se refiere a la reputación que tiene el solicitante en el cumplimiento del pago de obligaciones crediticias o de pagos de instalamentos periódicos, carácter que, en la actualidad, se estima a través de los puntajes de *scoring* otorgados por los *bureaus* de crédito que miden la probabilidad de pago de un posible deudor (Lara Haro, 2021; Morales Castro y Morales Castro, 2015).

Dado el volumen de información que poseen los *bureaus*, el puntaje de historial crediticio de una persona se calcula con la información contenida en bases de datos con respecto al pago o manejo de cuentas, tarjetas de crédito, créditos, servicios públicos y privados, impuestos y otros compromisos contratados con empresas del sector financiero y real, además de información sociodemográfica. Sin embargo, en casos de personas con poca o nula experiencia financiera, el prestamista tiene problemas de información asimétrica que dificultan tomar una decisión al no conocer lo suficiente del deudor.

La asimetría en la información restringe el crédito para quienes no han tenido experiencia financiera o para quienes por calamidades han tenido que dejar de cumplir con sus obligaciones y han generado rastros negativos en el historial crediticio. Como resultado de esta asimetría, los prestamistas enfrentan un problema de selección adversa, pues tienen incentivos para negar el crédito a clientes cuyo carácter desconocen (Mishkin y Eakings, 2012; Stiglitz y Weiss, 1981).

Como producto de la adopción en el sistema financiero de las recomendaciones del Comité de Basilea II en 2004 (Banco de Pagos Internacionales, 2006) y de la crisis financiera *subprime* de 2008, se puso en evidencia la falta de actualización de los modelos de *scoring* y la ausencia de variables explicativas relacionadas con el *default* en los modelos, así como el consecuente aumento de la información asimétrica (Bhidé, 2010; Jorion, 2011).

De ahí que recientemente se observe un creciente interés en el estudio de modelos de *scoring* que varían desde las técnicas a las variables incluidas para explicar

el *default*. Actualmente, la mayor parte de estos modelos están soportados en la información sociodemográfica y en datos sobre el comportamiento crediticio y financiero recolectado en los *bureaus*. La información con la que se mide el carácter crediticio es limitada porque se concentra en puntajes crediticios que califican a los potenciales deudores en función de su experiencia crediticia y que desconoce factores cognitivos y comportamentales que afectan la voluntad de pago, como los derivados de la pobreza (Mullainathan y Shafir, 2016), la capacidad de cálculo limitada (Simon, 1972), los sesgos comportamentales (Kahneman., 2012), la contabilidad mental (Sunstein *et al.*, 1998; Thaler, 2018), la deshonestidad y corrupción (Campos Vázquez, 2017); además que no considera algunos rasgos psicológicos involucrados con la toma de decisiones, como autocontrol, y las decisiones intertemporales (Thaler, 2018) y otros factores sociales, como normas sociales (Ariely, 2008).

En este marco, este artículo tiene por objetivo analizar la producción intelectual de artículos científicos que han involucrado factores psicológicos y comportamentales en la predicción o explicación del riesgo de crédito entre 2005 y 2023. Para lograr el objetivo, se realiza una revisión sistemática de la literatura (Whittemore *et al.*, 2014), siguiendo el protocolo PRISMA 2020 (Page *et al.*, 2021), de los artículos científicos publicados en las bases Scopus y Web of Science (WoS) para los años 2005-2023. Para el desarrollo de la revisión sistemática, se presentan los resultados con base en las secciones propuestas por Çall y Coşkun (2021).

De esta forma, los resultados descritos contribuyen a la literatura existente al identificar cómo se han operacionalizado y analizado los predictores psicológicos para evaluar el comportamiento crediticio de los individuos. Este análisis contribuye a generar un mayor entendimiento del *default* y el desarrollo de modelos de *scoring* más precisos que reduzcan la asimetría de información en el mercado de los créditos y, en consecuencia, mejoren la eficiencia en la asignación de créditos y permitan el acceso al crédito a población más vulnerable.

REVISIÓN DE LITERATURA

Las investigaciones para desarrollar modelos de *scoring* se iniciaron con el uso de información sociodemográfica y del método Delphi (Durand, 1941), y han venido evolucionando hasta la fecha gracias al poder de procesamiento de información de las computadoras, el surgimiento de la inteligencia artificial (IA) y el *machine learning* (ML). Entre las investigaciones de las últimas décadas para predecir el *default*, es evidente el interés de los investigadores por técnicas de aprendizaje autónomo que buscan principalmente mejorar la predicción y no tanto la explicación de las causas del *default*. Entre estas, se destacan varias investigaciones que, soportadas en modelos de redes neuronales (RN), buscan predecir el *default* y comparar con otras técnicas de clasificación tradicionales, como los modelos *logit* o *probit*, el análisis de supervivencia (AS), y otras técnicas que permiten encontrar las relaciones entre el comportamiento histórico y el *default* combinadas con otras variables.

Entre los trabajos que usan RN y AS e información del comportamiento crediticio histórico, se encuentra el de Baesens *et al.* (2005), quienes resaltan la efectividad de las RN en contextos de información poco comprensible; el de Noh *et al.* (2005), quienes compararon RN y AS con modelos *logit* y encontraron mínimas diferencias en la clasificación de clientes riesgosos y no riesgosos, y el de Sarlija *et al.* (2009), quienes subrayan la reducción del error tipo 1 de mala clasificación, esto es, el que predice un *default* que finalmente no se produce. En otras investigaciones, se utilizaron RN combinadas con otras técnicas, como análisis discriminante (AD) y modelos *logit* y *probit* (Abdou *et al.*, 2008), que evidenciaron un mejor desempeño de las redes con los modelos comparados y reducciones de los errores tipo 1 y 2 con su consecuente reducción de costos por mala clasificación.

Por su parte, Lanzarini *et al.* (2015, 2017) compararon RN con modelos de aprendizaje cuántico y de optimización por enjambres, tras lo cual constataron que los últimos generan una reducción de las variables explicativas y una mayor parsimonia que los modelos de RN. En otras investigaciones, se observa el interés de combinar RN con algoritmos de clasificación. Alborzi y Khanbabaie (2016) utilizaron técnicas de clasificación antes del análisis con RN y mejoraron los resultados. Por su parte, Kulkarni y Dhage (2019) destacan la superioridad de las RN y de la técnica Naive Bayes (NB).

Igualmente, se destaca el uso de RN comparadas con técnicas de clasificación, como árboles binomiales, *gradient boosted trees* (GBT), NB, *multiple instances learning* (MIL), *radial basis function* (RBF) y *support vector machine* (SVM). En este grupo, se cuenta el trabajo de Guo *et al.* (2016), quienes, con datos de Weibo, la red social china, explicaron el valor de un *score* genérico, y de Zhang *et al.* (2018), quienes destacan el mejor desempeño de las RN y el MIL en la precisión discriminante, y del RBF y SVM en la sensibilidad.

La combinación del AS y los modelos *logit* son frecuentes en la construcción de modelos discriminantes de crédito. Tong *et al.* (2012) hallaron buena clasificación de los modelos *logit* en rangos de 12 a 24 meses y 24 a 36 meses, mientras el AS fue más efectivo en rangos de 24 meses; además, relacionaron el destino de crédito como un factor discriminante del *default*. De igual manera, Bellotti y Crook (2013) adicionaron variables macroeconómicas y encontraron que el AS es más efectivo a mayor tiempo, mientras el modelo *logit* en 30 y 60 días de mora; además, la tasa de interés y el desempleo fueron factores que impactaron el impago, en especial, en condiciones económicas críticas.

Abdou *et al.* (2007) también compararon modelos *logit*, *probit* y AD, probando que el *logit* tiende a ser más efectivo en clasificación que el *probit* y el AD, pero que el costo del error tipo 2 es inferior con el AD que con los modelos *logit* y *probit*. Una novedosa metodología utilizada para clasificación es la de Roa *et al.* (2021), quienes utilizan la técnica GBT, que, aunque poco efectiva de forma individual, mejoró la clasificación al combinarse con el puntaje del *bureau*.

Chi y Hsu (2012), con información de un banco taiwanés y mediante algoritmos genéticos, relacionan de forma efectiva el *default* con el comportamiento histórico de pago y algunas variables sociodemográficas. Además, proponen estrategias de tasa para retención y cobranza con base en los resultados del *scoring*.

En esa misma línea, con datos comportamentales, San Pedro *et al.* (2015) desarrollaron un modelo con información de uso del teléfono celular y redes sociales, y establecieron un cambio de paradigma en la literatura, al utilizar información aparentemente no relacionada con el comportamiento crediticio. El estudio encontró que el modelo GBT con información del teléfono celular supera el desempeño del modelo *logit* y el SVM; además, sobrepasa el modelo de *bureau* en clientes con poco historial crediticio. Por su parte, Caruso *et al.* (2020) compararon cinco enfoques de *k-means* con información de la base UCI Machine Learning, hallando que en las cinco metodologías solo puede encontrarse un consenso en la tenencia de vivienda como un factor positivo para reducir el *default*; el destino menos riesgoso es compra de vehículos, contrariamente al mayor riesgo del destino emprendimiento.

A pesar de la diversidad de metodologías en la modelación del *scoring* y del esfuerzo por perfeccionar las técnicas de pronóstico, persisten vacíos en la discusión en torno a las fuentes de información usadas, ya que predomina el uso de bases de datos sobre historial crediticio, hecho que no corrige el problema de asimetría de información y selección adversa.

Asimismo, las investigaciones previas no pretenden explicar los constructos que justifican el uso de las variables seleccionadas ni el mecanismo que explicaría el *default*, por lo que el uso de variables alternativas, como las de comportamiento social o las psicológicas, es apenas incipiente. En este sentido, tan solo dos investigaciones se destacan en la literatura revisada porque no buscan explicar el *default*, sino capturar la percepción de expertos sobre los factores que lo determinan (Yu *et al.*, 2019), o establecer las variables más relevantes para evaluar el riesgo de crédito de clientes de consumo de una entidad financiera (Ferreira *et al.*, 2019).

La preocupación por las fuentes y los constructos hace necesario ampliar la discusión sobre *scoring* de crédito y examinar en detalle estudios referentes al uso de variables psicológicas y comportamentales para medir la propensión al *default*. La importancia de este análisis ha sido destacada por Aitken (2017) y Bernards (2019), quienes consideran que incluir ese tipo de variables para medir el riesgo de crédito se relaciona con los procesos de financiarización, en los que el ser humano se convierte en objeto de valor financiero, y por cifras del Banco Mundial (BM), que destacan que el problema de acceso a los servicios financieros en América Latina se evidencia en que menos del 50 % de la población accedió a créditos en 2021 (Klapper *et al.*, 2025), así como que 15 % de ellos no pudieron acceder por razones alusivas a centrales de riesgo, entre ellas, reportes adversos y falta de experiencia crediticia (Guerrero, 2022).

MÉTODO

Esta investigación es una revisión sistemática de literatura que, según Whittemore *et al.* (2014), es una técnica que combina evidencia de varios artículos, para identificar, evaluar y sintetizar los resultados de las investigaciones existentes en un campo de estudio. Este tipo de revisiones se caracterizan por seguir un proceso estandarizado de recolección, síntesis y reporte de resultados (Hernández *et al.*, 2021).

Los criterios de búsqueda se delimitaron por el *factor psycho*, que incluye los factores psicológicos de manera amplia, junto con los de personalidad, que, según la revisión de la introducción, fue un factor preponderante en las investigaciones que justifican esta revisión. Asimismo, las palabras clave relacionadas con riesgo de crédito fueron producto de evidenciar que no existe un consenso de términos para referirse a comportamiento crediticio o de pago, de tal manera que se amplió la búsqueda a factores relacionados con riesgo de crédito, *default* crediticio, solvencia y patrones de pago.

En primer lugar, la búsqueda de literatura se realizó en las bases Web of Science (WoS) y Scopus, utilizando como palabras clave *psycho* OR personality AND "credit scor*", "credit risk", "credit default", "default prediction", "creditworthiness", "payment behavior", "payment pattern"*. La búsqueda se limitó a artículos y revisiones publicados entre 2005 y 2023.

Los artículos obtenidos se revisaron por título y *abstract*, buscando identificar cuáles de ellos se referían a determinantes psicológicos relacionados con el *default*, los *scoring*, la voluntad o el comportamiento de pago.

Los criterios de elegibilidad de las búsquedas y depuraciones efectuadas pueden observarse en la figura 1 elaborada con base en la directriz Preferred Reporting Items for Systematic reviews and Meta-Analyses (PRISMA) 2020 (Page *et al.*, 2021).

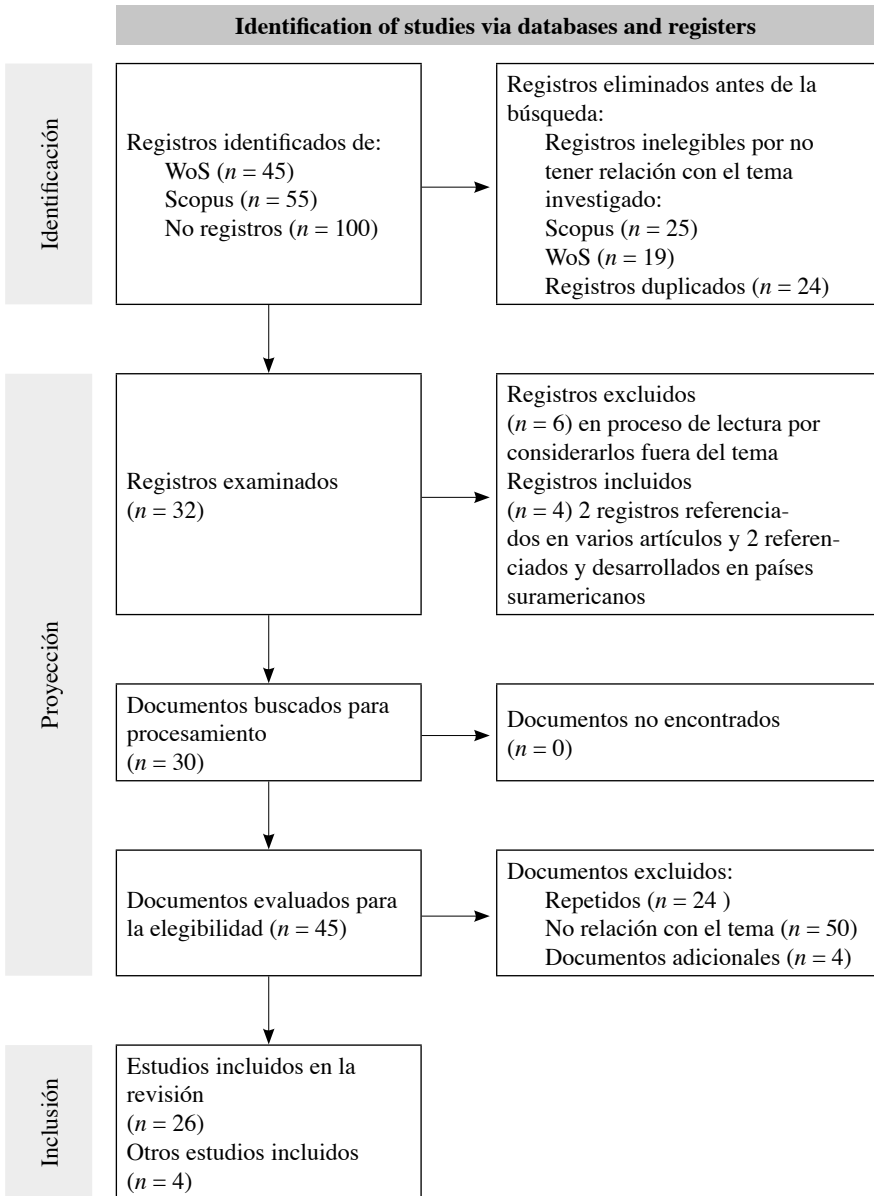
RESULTADOS

Como se indica en la figura 1, la búsqueda inicial arrojó 100 artículos, de los cuales se incluyeron 30 en esta revisión. A continuación, se presentan los resultados del análisis de los artículos con base en los elementos descritos en la revisión de literatura.

De acuerdo con la variable explicada de los 30 estudios seleccionados, 14 presentan el *default* como variable explicada. Klinger, *et al.* (2013) y Klinger *et al.* (2013) definen el *default* en mora de 30, 60 y 90 días. Liberati y Camillo (2018) lo explican como estar en sobregiro. Según Rogers *et al.* (2015), el *default* es considerado cuando el cliente tiene dos o más restricciones financieras. Woo y Sohn (2022) lo precisan como 120 días de mora, mientras, para Yang *et al.* (2022), la mora solo debe ser de 30 días.

Figura 1.

Flujo PRISMA para reporte de resultados de revisión de literatura



Nota. El análisis de los artículos seleccionados incluyó la comparación de la variable explicada, los predictores psicológicos y las técnicas de análisis usadas.

Fuente: elaboración propia con base en la directriz PRISMA 2020 (Page *et al.*, 2021).

Para otros autores, el *default* son retrasos o saldos no cancelados (Arráiz *et al.* 2017; Djeundje *et al.* 2021; Dlugosch *et al.* 2018; Zhou *et al.* 2021), o retraso en el pago de la factura del teléfono celular (Björkegren y Grissen, 2020). Dado que el comportamiento de pago puede estar influido por factores situacionales, Goel y Rastogi (2021a, 2021b) separan el *default* deliberado (cuando el deudor, aun teniendo los medios, no paga) y el *default* no deliberado que se da por cualquier otro factor que induzca el impago. También es común encontrar trabajos que usan el *scoring* FICO (Adams *et al.*, 2014; Arya *et al.*, 2013; Bernerth *et al.*, 2012; Fair Isaac Corporation [FICO], s. f.; Perry, 2008; Rustichini *et al.*, 2016) y otros que combinan información de factores bioquímicos, como un *proxy* del riesgo de pago de reclamaciones (Brockett y Golden, 2007; Golden *et al.*, 2016).

Otros estudios optan por la definición de una variable dicotómica que diferencia a quienes cumplen o incumplen sus obligaciones según la base UCI Machine Learning (University of California, s. f.), como en el estudio de Kulkarni y Dhage (2019), mientras algunos autores relacionan el uso de crédito *pay day loan* como un comportamiento riesgoso o *default* (Lee *et al.*, 2019).

Ghosh *et al.* (2020) indagan la morosidad general de la cartera del sistema. Entretanto, algunos autores como Hendricks y Budree (2019) buscan aumentar el uso de microcréditos con variables alternativas en la construcción del *scoring*, y Kim y Sohn (2016) determinar la importancia de las variables psicológicas en la construcción de un modelo experto de *scoring*.

Algunos trabajos tienen un interés más allá del *scoring*, pues se centran en analizar los determinantes del uso de créditos con la inclusión de variables psicológicas. En el trabajo pionero de Tokunaga (1993), se introducen variables psicológicas en el buen o mal uso de crédito y se construyen perfiles de personas con problemas de riesgo de crédito. Entretanto, Kamleitner *et al.* (2012) consideran el uso del crédito antes, durante y después de la solicitud, pues argumentan que los análisis suelen centrarse en la etapa que corresponde a la fase previa al otorgamiento del crédito.

En cuanto a las variables independientes, los principales predictores psicológicos para el *default* son la inteligencia, los rasgos *big five*, en especial, el neuroticismo, la apertura a la experiencia y simpatía, además del autocontrol, la autoeficacia e integridad, como se muestra en la tabla 1.

Tabla 1.
Consolidado de principales predictores

Principales predictores	Frecuencia
Inteligencia	8
Neuroticismo	7
Autoeficacia	6

(Continúa)

Principales predictores	Frecuencia
Autocontrol	6
<i>Big five</i>	5
Escrupulosidad	5
Preferencias temporales (impulsividad, impaciencia)	5
Integridad	5
Locus de control	5
Simpatía	4
Actitud hacia el dinero	4
Actitud hacia el riesgo	4
Conocimiento financiero	4
Sensación de búsqueda	4
Materialismo	4

Fuente: elaboración propia.

Por último, en relación con el tamaño de las muestras, la forma de recolección y las metodologías de medición generan una segmentación natural, ya que aquellas procesadas con minería de datos tienden a relacionarse con técnicas de *machine learning* (ML) o *deep learning* (DL), mientras las recolectadas con instrumentos de autorreporte tienden a ser procesadas con técnicas de clasificación más tradicionales.

La tabla 2 muestra que las técnicas utilizadas en las bases construidas con minería de datos buscan mejorar la predicción sin explicar las relaciones entre variables. Además, permiten encontrar patrones y relaciones no observables o difusas por tratarse de datos no estructurados en los que pueden encontrarse imágenes, textos dispersos, estados, frases, números, entre otros, por lo que son muy efectivas en el proceso de información de redes sociales, correos electrónicos o datos del uso del teléfono celular (tabla 2).

Tabla 2.

Técnicas utilizadas en bases procesadas con minería de datos

Autores	Tamaños de muestra	Técnicas
Kulkarni y Dhage (2019)	UCI Machine Learning 15 546 datos	<i>k-means</i> para separar clústeres, NB, RN <i>multilayer perceptron</i> (MLP), AA, bosques aleatorios

(Continúa)

Autores	Tamaños de muestra	Técnicas
Djeundje <i>et al.</i> (2021)	Grupo 1: 1370 datos psicométricos y demográficos 332 datos alternativos 1658 con datos mixtos	CP definición variables. Modelo mixto: <i>logit</i> , <i>regresión Ridge</i> , LASSO, <i>extreme gradient boosted</i> , RN
Björkegren y Grisen (2020)	7068 clientes	Bosques aleatorios y <i>logit</i>
Ghosh <i>et al.</i> (2020)	238 banqueros de 50 bancos en Bangladés	Mínimos cuadrados parciales en ecuaciones diferenciales
Rustichini <i>et al.</i> (2016)	1065 conductores de camión 942 con <i>score</i> FICO	Regresión lineal multivariada y análisis de correlación
Zhou <i>et al.</i> (2021)	Datos de 16 481 Periodo de gracia: 11 710 Morosos: 2211 <i>Default</i> : 2560	Para segmentar estados de bosques aleatorios, AdaBoost, XGBoost y apilamiento Para selección individual: SVM, RN, <i>logit</i> y combinaciones, bosques aleatorios, refuerzo adaptativo, Extreme GBT y meta-aprendizaje de apilamiento
Golden <i>et al.</i> (2016)	153 149 clientes con pólizas con <i>score</i> 22 284 sin información para calcular <i>scoring</i>	Estadística descriptiva, distribuciones de probabilidad, regresión lineal y <i>logit</i>
Woo y Sohn (2022)	55 820, de ellos: 7322 con registro de <i>default</i>	<i>Logit</i> y <i>logit</i> ponderada localmente.
Yang <i>et al.</i> (2022)	15 571 posts originales 13 709 clientes 1209: 63 riesgosos 1146 bajo riesgo	<i>k-means</i> detecta autoría de posts. Para obtener rasgos del procesamiento del lenguaje natural (PNL, por sus siglas en inglés). Detector de personalidad para prestatarios en línea (PDOB, por sus siglas en inglés) y modelo de evaluación de riesgos explicable (ERAM, por sus siglas en inglés) Representaciones de codificador bidireccional de transformadores (BERT, por sus siglas en inglés) para convertir resultados en variables explicables Árboles de decisión, AdaBoost, AD lineal, clasificador de embolsado y de bosque aleatorio y RN para vincular el <i>default</i>

Fuente: elaboración propia.

Por otro lado, en la tabla 3 se observa un resumen de las técnicas utilizadas en el procesamiento de la información para estudios que se soportaron en el autorreporte como medio de recolección de la información psicológica. Se destaca el uso de *logit* en ocho de ellos, combinados con técnicas, como análisis factorial, matrices de covarianza, procesos de jerarquía difusas o individualmente, y el de regresiones lineales en cuatro casos, componentes principales en dos casos combinados con SVM y con análisis multivariante y dos modelos de ecuaciones estructurales. Los modelos descritos buscan encontrar la mejor explicación de las relaciones entre la variable explicada, incluso por encima de la efectividad en la predicción del riesgo crediticio.

Tabla 3.

Técnicas utilizadas para información obtenida mediante autorreporte

Autores	Tamaños de muestra	Técnicas
Lee <i>et al.</i> (2019)	24 201 estudios de capacidades financieras en EE. UU. 2015	Ecuaciones estructurales
Arráiz <i>et al.</i> (2017)	1993 solicitantes de préstamos	Regresión lineal
Liberati y Camillo (2018)	7699 personas independientes 6160 buenos y 1539 malos	CP, SVM
Ganbat <i>et al.</i> (2021)	1118 aplicantes de crédito	Análisis factorial para validar desempeño de constructos, <i>logit</i> y alfa de Cronbach
Perry (2008)	8769 encuestas respondidas, sujetos entre 20 y 40 años	<i>Logit</i>
Arya <i>et al.</i> (2013)	66 sujetos, 63 observaciones	Regresión lineal
Dlugosch <i>et al.</i> (2018)	37 489 en América Latina, 1715 en bajo riesgo (Colombia, Perú, Sudáfrica, Kenia) y 35 774 de alto riesgo (México, Perú, Ghana, Kenia, Nigeria, Tanzania, Zimbabue, Botsuana, Namibia, Lesoto, Malawi, Suazilandia y Sudáfrica)	Matrices covarianza, <i>logit</i>
Rogers <i>et al.</i> (2015)	555 estudiantes o graduados MBA, trabajadores de compañía de limpieza, familiares investigadores	<i>Logit</i>

(Continúa)

Autores	Tamaños de muestra	Técnicas
Bernerth <i>et al.</i> (2012)	142 encuestas y 113 reportes de supervisores	Regresión lineal múltiple
Woo y Sohn (2022)		AHP, Converting Fuzzy data into Crisp Scores (CFCS) y <i>logit</i> para observar relaciones, Delphi
Goel y Rastogi (2021a, 2021b).	288 dueños de mipymes	CFA y <i>logit</i>
Wang <i>et al.</i> (2020)	713 respuestas de formulario	Ecuaciones estructurales
Adams <i>et al.</i> (2014)	484 fumadores y 1587 no fumadores	Matrices de correlación y regresión multivariada
Klinger <i>et al.</i> (2013)	275 empresas	<i>Logit</i> paso a paso
Klinger, Castro <i>et al.</i> (2013)	255 pymes, 29 con mora superior a 30 días	<i>Logit</i> paso a paso
Tokunaga (1993)	69 con problemas de crédito y 62 sin problemas de crédito	Correlación de Pearson y CP La viabilidad de variables psicométricas alfa de Cronbach, <i>multivariate analysis of variance</i> (MANOVA)

Fuente: elaboración propia.

DISCUSIÓN Y CONCLUSIONES

El análisis de la literatura refleja que no existe consenso en la variable explicada en las investigaciones relacionadas con los *scoring* en conjunto con variables psicológicas, lo cual obedece a diversos factores, como el tipo de artículo o de crédito. No obstante, lo que puede concluirse es que las variables pueden instrumentalizarse según los intereses investigativos y la información disponible, como los días de atraso, estar en sobregiro, el no pago del teléfono celular, el valor del *score*, la definición de incumplimiento establecida por la entidad, entre otros. Sin embargo, es necesario aclarar que el criterio no puede estandarizarse, ya que depende del tipo de cartera, producto, tipo de garantía, contexto social, económico e institución en la que se define.

En relación con los determinantes psicológicos del *default*, el modelo *big five* (BF) está bastante difundido junto con la inteligencia. Sin embargo, algunas investigaciones, como la de Rustichini *et al.* (2016), además de los BF, mezclaron preferencias temporales (PT), inteligencia y variables financieras, e identificaron que el neuroticismo reduce la preferencia por riesgo y la posibilidad de sobreendeudamiento, contrariamente a la AE. Además, la extroversión puede generar exceso de

confianza y promover actitudes financieras más riesgosas. Por su parte, Arya *et al.* (2013) encontraron vínculos del *default* con impaciencia e impulsividad en mayor riesgo de crédito.

Goel y Rastogi (2021b) concluyen que el locus de control (LC) interno y la autoeficacia se relacionan negativamente con el *default*, mientras el LC interno, la integridad, el materialismo, el autocontrol y la personalidad están relacionados positivamente con el *default*. Por su parte, Adams *et al.* (2014) conectan fumar con sensación de búsqueda y relacionan este hábito con la mala toma de decisiones financieras, las cuales conducen a un aumento de la deuda y el impago.

Bernerth *et al.* (2012) relacionaron el *scoring* crediticio con el desempeño laboral y agresiones o robos (integridad) en el lugar de trabajo, y encontraron una relación determinante entre bajo *scoring* y un mal comportamiento. Por su parte, Goel y Rastogi (2021a) evidenciaron que la autoeficacia y el LC interno tienen una relación negativa con la morosidad, mientras el LC externo, el materialismo, el neuroticismo y la simpatía se relacionaron positivamente con el impago. Asimismo, concluyeron que el *default* deliberado se relacionó positivamente con la integridad y la autoestima.

Para la modalidad de microcréditos, Ganbat *et al.* (2021) encontraron que los rasgos escrupulosidad y neuroticismo, junto con autocontrol, desinterés, actitud generosa y actitud hacia el dinero, explicaron el *default*. Además, evidenciaron relaciones negativas del neuroticismo con variables económicas y que los rasgos psicológicos influyen de forma diferente en el impago según la edad.

Entre las investigaciones que incluyeron el *scoring* del Enterprise Finance Lab (EFL) que implican los BF, Dlugosch *et al.* (2018) encontraron que la forma en que se recopila la información psicológica puede influir en el resultado, dado que, si el puntaje es un criterio para la decisión de crédito (alta apuesta), genera que el solicitante busque manejar sus respuestas para aumentar la probabilidad de aprobación. Por otro lado, hallaron que escrupulosidad, extroversión, neuroticismo e integridad son variables relevantes para explicar el *default*. Klinger, Castro *et al.* (2013) y Klinger *et al.* (2013) notaron que el *scoring* EFL con variables psicológicas es buen clasificador y reduce la asimetría de información, así como que la inteligencia es un buen predictor del *default*. Arráiz *et al.* (2017) evidenciaron que el *scoring* EFL no mejora la clasificación para empresarios bancarizados, pero sí para los no bancarizados. Björkegren y Grissen (2020) demostraron que el *score* del EFL sobrepasa, en la efectividad de la clasificación, a los *bureau* tradicionales, en especial, cuando se trata de clientes con poca o sin experiencia financiera.

Yang *et al.* (2022), a través de la escritura de posts en la red social Weibo, encontraron que neuroticismo y AE pueden explicar en parte el *default*. Zhou *et al.* (2021) relacionaron los BF con el uso del teléfono celular para predecir el *default*, y evidenciaron un vínculo de la morosidad con neuroticismo y AE; además, escrupulosidad puntuó como el factor más importante de los BF en relación con el riesgo de *default*. Por último, Kim y Sohn (2016) construyeron una variable compuesta

por factores psicológicos en la que un panel de expertos consideró la inteligencia, autoeficacia e integridad como factores relevantes a incluir.

Los vínculos de los BF con otros factores psicológicos, económicos, financieros y sociodemográficos son condensados por Çall y Coşkun (2021), quienes identifican relaciones del *default* con autocontrol, inteligencia, LC, autoeficacia, simpatía, optimismo, autoestima e impulsividad. Además, resaltan factores comportamentales, como actitud hacia el dinero, creencias monetarias, actitudes hacia la toma de riesgos y crédito, compra compulsiva y conocimiento financiero.

El LC es una variable que estuvo presente en cinco investigaciones de la base, algunas de las relaciones se observan en Perry (2008), que, junto con factores situacionales y el conocimiento financiero como factor cognitivo, fueron aspectos relevantes para explicar el impago. De igual manera, Rogers *et al.* (2015) evidenciaron que el LC es una variable relevante para mantener un buen o mal comportamiento crediticio, junto con el significado del dinero, la autoeficacia y la compra compulsiva.

Kamleitner *et al.* (2012) constataron relaciones del LC con el buen uso del crédito y lo vincularon con variables psicológicas y comportamentales, como cuentas mentales, actitud hacia el dinero y crédito, conocimiento financiero, normas sociales y descuentos temporales. Por su parte, Tokunaga (1993) también relacionó el mal uso del crédito con LC, extravagancia, ostentosis, impaciencia, autoeficacia, autoestima, actitud frente al riesgo y SB, que se vincula con la voluntad de tomar riesgos.

El autocontrol también ha sido importante en trabajos como el Golden *et al.* (2016), quienes lo vinculan con las reclamaciones de seguros, junto con variables como SB, responsabilidad y aceptación de riesgos. Un vínculo del autocontrol con compra compulsiva, impulsividad y *scoring* se dio en la investigación de Brockett y Golden (2007) por medio de la variable SB, que aumenta la propensión a asumir riesgos y comportamientos irresponsables. La autoeficacia, reflejada en exceso o falta de confianza, puede llevar a la adquisición de deudas costosas que pueden desencadenar *default*, como lo muestran Lee *et al.* (2019), quienes encontraron cómo una baja autopercepción llevó a personas a solicitar créditos *pay day loan* (en general, muy onerosos), pese a que tenían el perfil de acceder a los servicios bancarios formales.

Liberati y Camillo (2018) utilizaron semiometría para reducir el riesgo de manipulación de las pruebas psicométricas, y comprobaron que rasgos psicológicos como conformismo, apego y preferencia entre deber y placer fueron importantes en la mejora de la predicción del riesgo en conjunto con los datos de *bureau*, pero no son autosuficientes para predecir el riesgo crediticio individual sin los datos del *scoring*.

Ghosh *et al.* (2020) vinculan el nepotismo, el incumplimiento de la norma social y la disonancia cognitiva como los causantes del incremento de la morosidad en

el sistema financiero en Bangladés. Woo y Sohn (2022), a través de los perfiles Myers-Briggs Type Indicator (MBTI), relacionaron la morosidad con el factor sensibilidad en tres de los perfiles MBTI; además, constataron que el grupo con la combinación introversión, intuición, sensibilidad y percepción tuvo la máxima mora, con un nivel del 16,59 %.

Djeundje *et al.* (2021) buscaron mejorar el desempeño de un *score* crediticio, que incluyó variables de uso de correo y psicológicas, tras lo cual encontraron que el retraso o adelanto de la gratificación, el egoísmo y la agilidad mental pueden ayudar a explicar el mal comportamiento crediticio. Finalmente, con respecto a las investigaciones soportadas en información del uso del teléfono celular y las redes sociales, Hendricks y Budree (2019) concluyen que existen disuasores del incumplimiento, como el uso de garantías. Kulkarni y Dhage (2019) demuestran que no hay una explicación teórica de los vínculos con factores psicológicos y aseveran que el comportamiento en el manejo de redes sociales refleja factores psicológicos que influyen en el comportamiento de pago.

Puede evidenciarse que la literatura que relaciona los *scoring* con variables psicológicas ha tenido una mayor relevancia desde 2005 debido a la promulgación del Acuerdo de Basilea II por sus implicaciones en el cálculo de provisiones y capital (Acuerdo de Basilea II, 2004). Además que los principales países donde se han hecho desarrollos de *scoring* con variables psicológicas se concentran en Estados Unidos (Adams *et al.*, 2014; Arya *et al.*, 2013; Bernerth *et al.*, 2012; Golden *et al.*, 2016; Lee *et al.*, 2019; Perry, 2008; Rustichini *et al.*, 2016; Tokunaga, 1993; Woo y Sohn, 2022), China (Wang *et al.*, 2020; Yang *et al.*, 2022; Zhou *et al.*, 2021) y América Latina (Arráiz *et al.*, 2017; Dlugosch *et al.*, 2018; Klinger, Khwaja *et al.*, 2013); Perú es el país latinoamericano con mayor número de desarrollos, especialmente, en bancos. De igual manera, puede observarse que los escenarios preferidos por los investigadores son los bancos y las entidades crediticias por su naturaleza y actividad económica, pero que las universidades y compañías de transporte y de seguros son escenarios que permiten recopilar información para este tipo de desarrollos.

Los resultados de esta investigación evidencian un reducido número de estudios que buscan explicar el *default* a partir de factores psicológicos y comportamentales, en especial, en países en vías de desarrollo donde la asimetría de la información suele ser mayor. Además, se observa un vacío en el sentido que pocos autores relacionan el *default* con el carácter crediticio del análisis de crédito y una diversidad de finalidades del uso de variables psicológicas con el *scoring*, como inferir comportamientos en el trabajo o en reclamaciones de seguro, lo cual genera una oportunidad de profundizar en estas variables, a fin de que puedan ser utilizadas no solo en la industria del crédito, sino en otras industrias, para explicar comportamientos y reducir los riesgos.

La revisión llevada a cabo en esta investigación da cuenta de la diversidad de técnicas de modelación del riesgo de crédito y de la importancia creciente de los determinantes psicológicos. La literatura revisada demuestra que, aunque se han

identificados determinantes psicológicos para el *default*, que incluyen el reconocimiento de sesgos cognitivos, problemas de cálculo mental y normas sociales, entre otros, persiste la falta de consenso sobre los determinantes psicológicos.

Los estudios posteriores sobre el abordaje de determinantes psicológicos pueden avanzar en el desarrollo de modelos parsimoniosos que puedan ser combinados con las técnicas estándar de información sociodemográfica, para elevar el poder explicativo de los modelos. Asimismo, se requiere la realización de estudios de relaciones causales con el uso de métodos experimentales entre los predictores psicológicos y el *default*, con el fin de optimizar la selección de variables que determinan el comportamiento de pago individual.

Frente a las revisiones sistemáticas de literatura, es necesario avanzar en otras técnicas de síntesis de resultados de investigación, por ejemplo, las revisiones meta-analíticas.

Por último, se encontró que los modelos construidos con información psicológica se construyen principalmente con bases de entidades financieras, *fintech*, redes sociales o bases genéricas, y dejan de lado los datos de prestamistas informales, quienes son los que asumen los riesgos de la asimetría de información y otorgan el crédito a aquellos que no logran acceder a productos de crédito formal.

REFERENCIAS

1. Abdou, H., El-Masry, A., & Pointon, J. (2007). On the applicability of credit scoring models in Egyptian banks. *Banks and Bank Systems*, 2(1), 4-20. https://www.businessperspectives.org/index.php/journals?controller=pdfview&task=download&item_id=1607
2. Abdou, H., Pointon, J., & El-Masry, A. (2008). Neural nets versus conventional techniques in credit scoring in Egyptian banking. *Expert Systems with Applications*, 35(3), 1275-1292. <https://doi.org/10.1016/j.eswa.2007.08.030>
3. Adams, S., Bose, N., & Rustichini, A. (2014). How different are smokers? An analysis based on personal finances. *Journal of Economic Behavior & Organization*, 107, 40-50. <https://doi.org/10.1016/j.jebo.2014.08.003>
4. Aitken, R. (2017). "All data is credit data": Constituting the unbanked". *Competition & Change*, 21(4), 274-300. <https://doi.org/10.1177/1024529417712830>
5. Alborzi, M., & Khanbabaee, M. (2016). Using data mining and neural networks techniques to propose a new hybrid customer behaviour analysis and credit scoring model in banking services based on a developed RFM analysis method. *International Journal of Business Information Systems*, 23(1), 1-22. <https://doi.org/10.1504/IJBIS.2016.078020>
6. Ariely, D. (2008). *Las trampas del deseo* (4.ª ed.). Planeta.

7. Arráiz, I., Bruhn, M., & Stucchi, R. (2017). Psychometrics as a tool to improve credit information. *World Bank Economic Review*, 30, S67-S76. <https://doi.org/10.1093/wber/lhw016>
8. Arya, S., Eckel, C., & Wichman, C. (2013). Anatomy of the credit score. *Journal of Economic Behavior & Organization*, 95, 175-185. <https://doi.org/10.1016/j.jebo.2011.05.005>
9. Baesens, B., Van Gestel, T., Stepanova, M., Van den Poel, D., & Vanthienen, J. (2005). Neural network survival analysis for personal loan data. *Journal of the Operational Research Society*, 56(9), 1089-1098, <https://doi.org/10.1057/palgrave.jors.2601990>
10. Banco de Pagos Internacionales. (2006). *Convergencia internacional de medidas y normas de capital*. https://www.bis.org/publ/bcbs128_es.pdf
11. Bellotti, T., & Crook, J. (2013). Forecasting and stress testing credit card default using dynamic models. *International Journal of Forecasting*, 29(4), 563-574. <https://doi.org/10.1016/j.ijforecast.2013.04.003>
12. Bernards, N. (2019). The poverty of fintech? Psychometrics, credit infrastructures, and the limits of financialization. *Review of International Political Economy*, 26(5), 815-838. <https://doi.org/10.1080/09692290.2019.1597753>
13. Bernerth, J. B., Taylor, S. G., Walker, H. J., & Whitman, D. S. (2012). An empirical investigation of dispositional antecedents and performance-related outcomes of credit scores. *Journal of Applied Psychology*, 97(2), 469-478. <https://doi.org/10.1037/a0026055>
14. Bhidé, A. (2010). The big idea: The judgment deficit. *Harvard Business Review*, 88(9). <http://www.bolderenterprises.com/wp-content/uploads/2010/12/hbr-the-judgment-deficit.pdf>
15. Björkegren, D., & Grissen, D. (2020). Behavior revealed in mobile phone usage predicts credit repayment. *The World Bank Economic Review*, 34, 618-634. <https://doi.org/10.1093/wber/lhz006>
16. Brockett, P. L., & Golden, L. L. (2007). Biological and psychobehavioral correlates of credit scores and automobile insurance losses: Toward an explication of why credit scoring works. *Journal of Risk and Insurance*, 74(1), 23-63. <https://doi.org/10.1111/j.1539-6975.2007.00201.x>
17. Çall, B. A., & Coşkun, E. (2021). A longitudinal systematic review of credit risk assessment and credit default predictors. *Sage Open*, 11(4). <https://doi.org/10.1177/21582440211061333>
18. Campos Vázquez, R.M. (2017). *Economía y psicología: Apuntes sobre economía conductual para entender problemas económicos actuales*. Fondo de Cultura Económica.
19. Caruso, G., Gattone, S., Fortuna, F., & Battista, T. (2020). Cluster Analysis for mixed data: An application to credit risk evaluation. *Socio-Economic Planning Sciences*, 73. <https://doi.org/10.1016/j.seps.2020.100850>


20. Chi, B.-W., & Hsu, C.-C. (2012). A hybrid approach to integrate genetic algorithm into dual scoring model in enhancing the performance of credit scoring model. *Expert Systems with Applications*, 39, 2650-2661. <https://doi.org/10.1016/j.eswa.2011.08.120>
21. Djeundje, V. B., Crook, J., Calabrese, R., & Hamid, M. (2021). Enhancing credit scoring with alternative data. *Expert Systems with Applications*, 163. <https://doi.org/10.1016/j.eswa.2020.113766>
22. Dlugosch, T. J., Klinger, B., Frese, M., & Klehe, U. C. (2018). Personality-based selection of entrepreneurial borrowers to reduce credit risk: Two studies on prediction models in low- and high-stakes settings in developing countries. *Journal of Organizational Behavior*, 39(5), 612-628. <https://doi.org/10.1002/job.2236>
23. Durand, D. (1941). *Risk elements in consumer instalment financing*. National Bureau of Economic Research. <https://EconPapers.repec.org/RePEc:nbr:nberbk:dura41-1>
24. Ferreira, F., Meidute-Kavaliauskiene, I., Zavadskas, E., Jalali, M., & Catarino, S. (2019). A judgment-based risk assessment framework for consumer loans. *International Journal of Information Technology & Decision Making*, 18(1), 7-33. <https://doi.org/10.1142/S021962201850044X>
25. Fair Isaac Corporation. (s. f.). *FICO® Score - The Best Credit Score in the Market*. <https://www.ficoscore.com/>
26. Friedman, M. (1959). *A program for monetary stability*. Fordham University Press.
27. Ganbat, M., Batbaatar, E., Bazarragchaа, G., Ider, T., Gantumur, E., Dashkhorol, L., Altantsatsralt, K., Nemekh, M., Dashdondog, E., & Namsrai, O. E. (2021). Effect of psychological factors on credit risk: A case study of the microlending service in Mongolia. *Behavioral Sciences*, 11(4). <https://doi.org/10.3390/bs11040047>
28. Ghosh, R., Sen, K. K., & Riva, F. (2020). Behavioral determinants of non-performing loans in Bangladesh. *Asian Journal of Accounting Research*, 5(2), 327-340. <https://doi.org/10.1108/AJAR-03-2020-0018>
29. Goel, A., & Rastogi, S. (2021a). Credit scoring of small and medium enterprises: A behavioural approach. *Journal of Entrepreneurship in Emerging Economies*, 15(1), 46-69. <https://doi.org/10.1108/JEEE-03-2021-0093>
30. Goel, A., & Rastogi, S. (2021b). Understanding the impact of borrowers' behavioural and psychological traits on credit default: Review and conceptual model. *Review of Behavioral Finance*, 15(2), 205-223. <https://doi.org/10.1108/RBF-03-2021-0051>
31. Golden, L. L., Brockett, P. L., Ai, J., & Kellison, B. (2016). Empirical evidence on the use of credit scoring for predicting insurance losses with psycho-social and biochemical explanations. *North American Actuarial Journal*, 20(3), 233-251. <https://doi.org/10.1080/10920277.2016.1209118>

32. Guerrero, D. (2022, 10 de abril). *El acceso a crédito es nulo o escaso para 23 millones de colombianos*. Bloomberg. <https://www.bloomberglinea.com/2022/04/10/el-acceso-a-credito-es-nulo-o-escaso-para-23-millones-de-colombianos/>
33. Guo, G., Zhu, F., Chen, E., Liu, Q., Wu, L., & Guan, C. (2016). From footprint to evidence: An exploratory study of mining social data for credit scoring. *ACM Transactions on the Web*, 10(4), 1-38. <https://doi.org/10.1145/2996465>
34. Hendricks, M. K., & Budree, A. (2019). Can a mobile credit-scoring model provide better accessibility to South African citizens requiring micro-lending? *International Journal of Electronic Finance*, 9(3), 157-169. <https://doi.org/10.1504/IJEF.2019.099001>
35. Hernández, F., Plaza, J., & Kreither, J. (2021). Trastorno por déficit atencional e hiperactividad en adultos: Una revisión sistemática de abordajes terapéuticos. *Psicoperspectivas: Individuo y Sociedad*, 20(1). <https://doi.org/10.5027/psicoperspectivas-vol20-issue1-fulltext-2095>
36. Jorion, P. (2011). *Financial risk manager handbook*. Wiley. <https://books.google.com.co/books?id=LmHYzQEACAAJ>
37. Kahneman, D. (2012). *Pensar rápido, pensar despacio*. Debate.
38. Kamleitner, B., Hoelzl, E., & Kirchler, E. (2012). Credit use: Psychological perspectives on a multifaceted phenomenon. *International Journal of Psychology*, 47(1), 1-27. <https://doi.org/10.1080/00207594.2011.628674>
39. Keynes, J. M. (2014). *Teoría general de la ocupación, el interés y el dinero*. Fondo de Cultura Económica.
40. Kim, D. H., & Sohn, S. Y. (2016). Fuzzy analytic hierarchy process applied to technology credit scorecard considering entrepreneurs' psychological and behavioral attributes. *Journal of Intelligent and Fuzzy Systems*, 30(4), 2349-2364. <https://doi.org/10.3233/IFS-152005>
41. Klapper, L., Singer, D., Starita, L., & Norris, A. (2025). *The Global Findex Database 2025: Connectivity and Financial Inclusion in the Digital Economy*. World Bank. <https://openknowledge.worldbank.org/bitstreams/9288bdc5-7a9b-42de-a47c-3746fd68f22a/download>
42. Klinger, B., Castro, L., Szenkman, P., & Khwaja, A. (2013). Unlocking SME finance in Argentina with Psychometrics. *IDB Technical Note*, 532. <https://doi.org/10.18235/0009112>
43. Klinger, B., Khwaja, A., & LaMonte, J. (2013). Improving credit risk analysis with psychometrics in Peru. *IDB Technical Note*, 587. <https://doi.org/10.18235/0009139>
44. Kulkarni, S. V., & Dhage, S. N. (2019). Advanced credit score calculation using social media and machine learning. *Journal of Intelligent and Fuzzy Systems*, 36(3), 2373-2380. <https://doi.org/10.3233/JIFS-169948>

45. Lanzarini, L. C., Villa Monte, A., Fernández-Bariviera, A., & Jimbo Santana, P. (2015). Obtaining classification rules using LVQ +PSO: An application to credit risk. En Y. Tan, Y. Shi, F. Buarque, A. Gelbukh, S. Das, & A. Engelbrecht (eds.), *Advances in Intelligent Systems and Computing* (pp. 383-391). Springer. https://doi.org/10.1007/978-3-319-20466-6_20
46. Lanzarini, L. C., Villa Monte, A., Fernández-Bariviera, A., & Jimbo Santana, P. (2017). Simplifying credit scoring rules using LVQ + PSO. *Kybernetes*, 46(1), 8-16. <https://doi.org/10.1108/K-06-2016-0158>
47. Lara Haro, A. de. (2021). *Medición y control de riesgos financieros* (3.^a ed.). Limusa.
48. Lee, J. M., Park, N., & Heo, W. (2019). Importance of subjective financial knowledge and perceived credit score in payday loan use. *International Journal of Financial Studies*, 7(3). <https://doi.org/10.3390/ijfs7030053>
49. Liberati, C., & Camillo, F. (2018). Personal values and credit scoring: New insights in the financial prediction. *Journal of the Operational Research Society*, 69(12), 1994-2005. <https://doi.org/10.1080/01605682.2017.1417684>
50. Minsky, H., & Kaufman, H. (2008). *Stabilizing an unstable economy*. McGraw Hill.
51. Mishkin, F., & Eakings, S. (2012). *Financial markets and institutions* (7.^a ed.). Prentice Hall.
52. Morales Castro, A., & Morales Castro, J. A. (2015). *Crédito y cobranza*. Grupo Editorial Patria.
53. Mullainathan, S., & Shafir, E. (2016). *Escasez: ¿Por qué tener poco significa tanto?* Fondo de Cultura Económica.
54. Noh, H. J., Roh, T. H., & Han, I. (2005). Prognostic personal credit risk model considering censored information. *Expert Systems with Applications*, 28(4), 753-762. <https://doi.org/10.1016/j.eswa.2004.12.032>
55. Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). Declaración PRISMA 2020: Una guía actualizada para la publicación de revisiones sistemáticas. *Revista Española de Cardiología*, 74(9), 790-799. <https://doi.org/10.1016/j.rec.2021.07.010>
56. Parkin, M. y Loría Díaz, E. (2010). *Microeconomía*. Pearson Education.
57. Perry, V. G. (2008). Giving credit where credit is due: The psychology of credit ratings. *Journal of Behavioral Finance*, 9(1), 15-21. <https://doi.org/10.1080/15427560801896784>
58. Roa, L., Correa-Bahnsen, A., Suarez, G., Cortés-Tejada, F., Luque, M. A., & Bravo, C. (2021). Super-app behavioral patterns in credit risk models:

- Financial, statistical and regulatory implications. *Expert Systems with Applications*, 169. <https://doi.org/10.1016/j.eswa.2020.114486>
59. Rogers, P., Rogers, D., & Securato, J. (2015). About psychological variables in application scoring models. *Revista de Administração de Empresas*, 55, 38-49. <https://doi.org/10.1590/S0034-759020150105>
 60. Rustichini, A., DeYoung, C. G., Anderson, J. E., & Burks, S. V. (2016). Toward the integration of personality theory and decision theory in explaining economic behavior: An experimental investigation. *Journal of Behavioral and Experimental Economics*, 64, 122-137. <https://doi.org/10.1016/j.socecon.2016.04.019>
 61. San Pedro, J. S., Proserpio, D., & Oliver, N. (2015). Mobiscore: Towards universal credit scoring from mobile phone data. En *User Modeling, Adaptation and Personalization: 23rd International Conference, UMAP 2015, Dublin, Ireland, June 29 - July 3, 2015. Proceedings* (pp. 195-207). Springer. https://doi.org/10.1007/978-3-319-20267-9_16
 62. Sarlija, N., Bencic, M., & Zekic-Susac, M. (2009). Comparison procedure of predicting the time to default in behavioural scoring. *Expert Systems with Applications*, 36(5), 8778-8788. <https://doi.org/10.1016/j.eswa.2008.11.042>
 63. Simon, H. A. (1972). *El comportamiento administrativo: Estudio de los procesos de adopción de decisiones en la organización administrativa*. Aguilar.
 64. Stiglitz, J. E., & Weiss, A. (1981). Credit rationing in markets with imperfect information. *The American Economic Review*, 71(3), 393-410. <http://www.jstor.org/stable/1802787>
 65. Sunstein, C. R., Jolls, C., & Thaler, R. (1998). A behavioral approach to law and economics. *Stanford Law Review*, 50, 1471-1550. https://chicagounbound.uchicago.edu/cgi/viewcontent.cgi?article=12172&context=journal_articles
 66. Thaler, R. D. (2018). *Todo lo que he aprendido con la psicología económica*. Deusto.
 67. Tokunaga, H. (1993). The use and abuse of consumer credit: Application of psychological theory and research. *Journal of Economic Psychology*, 14, 285-316. [https://doi.org/10.1016/0167-4870\(93\)90004-5](https://doi.org/10.1016/0167-4870(93)90004-5)
 68. Tong, E. N. C., Mues, C., & Thomas, L. C. (2012). Mixture cure models in credit scoring: If and when borrowers default. *European Journal of Operational Research*, 218(1), 132-139. <https://doi.org/10.1016/j.ejor.2011.10.007>
 69. University of California. (s. f.). UCI Machine Learning. <https://archive.ics.uci.edu/>
 70. Wang, X., Xu, Y. C., Lu, T., & Zhang, C. (2020). Why do borrowers default on online loans? An inquiry of their psychology mechanism. *Internet Research*, 30(4), 1203-1228. <https://doi.org/10.1108/INTR-05-2019-0183>

71. Whittemore, R., Chao, A., Jang, M., Minges, K. E., & Park, C. (2014). Methods for knowledge synthesis: An overview. *Heart & Lung, 43*(5), 453-461. <https://doi.org/10.1016/j.hrtlng.2014.05.014>
72. Woo, H., & Sohn, S. Y. (2022). A credit scoring model based on the Myers-Briggs type indicator in online peer-to-peer lending. *Financial Innovation, 8*(1). <https://doi.org/10.1186/s40854-022-00347-4>
73. Yang, K., Yuan, H., & Lau, R. Y. K. (2022). PsyCredit: An interpretable deep learning-based credit assessment approach facilitated by psychometric natural language processing. *Expert Systems with Applications, 198*. <https://doi.org/10.1016/j.eswa.2022.116847>
74. Yu, J., Yao, J., & Chen, Y. (2019). Credit scoring with AHP and fuzzy comprehensive evaluation based on behavioural data from weibo platform. *Tehnicki Vjesnik, 26*(2), 462-470. <https://doi.org/10.17559/TV-20181217180231>
75. Zhang, T., Zhang, W., Xu, W., & Hao, H. (2018). Multiple instance learning for credit risk assessment with transaction data. *Knowledge-Based Systems, 161*, 65-77. <https://doi.org/10.1016/j.knosys.2018.07.030>
76. Zhou, J., Wang, C., Ren, F., & Chen, G. (2021). Inferring multi-stage risk for online consumer credit services: An integrated scheme using data augmentation and model enhancement. *Decision Support Systems, 149*. <https://doi.org/10.1016/j.dss.2021.113611>



CUADERNOS DE ECONOMÍA

ISSN 0121-4772

ARTÍCULOS

- JESÚS ALBERTO PARADA PÉREZ Y CAMILO ALMANZA RAMÍREZ
¿Involución o evolución en la competitividad de los sectores económicos en Colombia?:
Una mirada desde la teoría de la complejidad económica 1
- JOSÉ LUIS MARTÍNEZ CAMPO, NOÉ VELÁZQUEZ-ESPINOZA Y HÉCTOR CUEVAS-VARGAS
Relación entre capacidad de reconfiguración y capacidad de innovación:
una aplicación en el sector hotelero 41
- JOSÉ REYES BERNAL-BELLÓN, JAVIER OSWALDO RODRÍGUEZ VELÁSQUEZ, SANDRA CATALINA CORREA HERRERA,
SIGNED ESPERANZA PRIETO BOHÓRQUEZ Y JORGE ELIÉCER GAITÁN MÉNDEZ
Predicción de la relación marginal capital-producto para China: una aplicación de la
caminata al azar probabilística 73
- JESÚS FERNANDO BARRIOS ORDÓÑEZ
Brecha digital en Colombia: ¿quiénes se conectan, cómo y para qué? 87
- OMAR NEME CASTILLO Y CESAIRE CHIATCHOUA
FDI and poverty in Mexican states (2010-2020) 133
- RICARDO ANTONIO SÁNCHEZ CÁRCAMO Y JOHNKER AUGUSTO SANTAMARÍA RAMOS
Aproximaciones hacia una economía para la paz. De la seguridad ontológica a la
seguridad diacrónica en Colombia 2000-2018 173
- ANA FLÁVIA MACHADO, MARIANGELA FURLAN ANTIGO, ALICE DEMATTOS GUIMARÃES, JONAS SULURICO,
FERNANDO UBA CARIÊLO VIEIRA Y MARIA EDUARDA GUIMARÃES
Survival in art occupations: The case of Brazilian state capitals 203
- MARCOS TOSTES LAMONICA Y SERGIANY DA SILVA LIM
Fragilidade financeira no setor industrial brasileiro, 2007-2018: uma análise usando VEC
com painel cointegrado 231
- LIBARDO ROJAS-VELÁSQUEZ, CAMILO FABIAN GÓMEZ SEGURA Y ÓSCAR HERNÁN CERQUERA LOSADA
Exclusión laboral y educativa de los jóvenes en Colombia antes y después del COVID-19 265
- LEOPOLDO GÓMEZ-RAMÍREZ Y JORGE QUINTERO OTERO
A model for teaching oil shocks in a small, open, oil-exporting, and developing economy 295
- JOSÉ CARLOS GONZÁLEZ NÚÑEZ Y FERNANDO MARINÉ OSORIO
Las variables de comportamiento que determinan la tenencia de crédito en México:
un análisis empírico 329
- JHON ALVARO PÉREZ CRUZ, CLAUDIA MILENA PICO BONILLA Y SUELEN EMILIA CASTIBLANCO MORENO
Modelación del *scoring* de crédito: una revisión sistemática de literatura de
sus determinantes psicológicos 359

ISSN 0121-4772



9 770121 477005 97