

El riesgo de crédito. Un recuento histórico y nuevas perspectivas para su mejor gestión

Credit Risk: A Historical Overview and New Perspectives for Better Management

Javier Arturo MARTÍNEZ FARFAN¹ , Elizabeth LÓPEZ MELÉNDEZ²  , Luis David LARA RODRÍGUEZ³  

1 Universidad Privada San Juan Bautista, Derecho, Ciencias Empresariales y Administración de Empresas. Ica, Perú.

2 Universidad Tecnológica de Huejotzingo, Mecatrónica. Huejotzingo, México.

3 Universidad Politécnica de Puebla, Tecnologías de la Información, Puebla, México.

Email: javier.martinez@upsjb.edu.pe; elizabeth.lopez@uth.edu.mx; luis.lara406@up Puebla.edu.mx

Resumen

El riesgo crediticio constituye un pilar esencial en la gestión financiera contemporánea, particularmente tras la crisis financiera de 2007 que evidenció las fragilidades sistémicas presentes en inversores, instituciones financieras y economías previamente consideradas sólidas. De esta manera, se genera la imperante necesidad de desarrollar enfoques innovadores para su efectiva mitigación. Esta investigación examina la problemática asimétrica que impacta a entidades de múltiples escalas operativas, desde organizaciones microfinancieras hasta aquellas sujetas a los rigurosos requerimientos establecidos por Basilea IV. Se proponen estrategias de carácter proactivo diseñadas para confrontar la creciente complejidad que caracteriza a los mercados financieros globalizados, en los que la capacidad de anticipación y la precisión analítica se han consolidado como factores determinantes para garantizar la estabilidad institucional. El presente estudio integra metodologías tradicionales de evaluación crediticia con los más recientes desarrollos en ciencia de datos e inteligencia artificial. Configura un marco analítico comprehensivo que permite evaluar y gestionar el riesgo crediticio de manera sistemática y eficiente en el contexto financiero actual.

Palabras Clave

Administración financiera, Instituciones financieras, crédito, dinero, inteligencia artificial, aprendizaje automático.

Abstract

Credit risk is an essential pillar of contemporary financial management, particularly in the wake of the 2007 financial crisis, which exposed systemic weaknesses in investors, financial institutions, and economies previously considered solid, thus creating a pressing need to develop innovative approaches for its effective mitigation. This research examines the asymmetric problem that affects entities of multiple operational scales, from microfinance organizations to those subject to the rigorous requirements established by Basel IV, proposing proactive strategies designed to confront the growing complexity that characterizes globalized financial markets, where the ability to anticipate and analytical precision have become determining factors in ensuring institutional stability. This study integrates traditional credit assessment methodologies with the latest developments in data science and artificial intelligence, providing a comprehensive analytical framework that allows for the systematic and efficient assessment and management of credit risk in the current financial context.

Keywords

Financial Management, Financial Institutions, Credit, Money, Artificial Intelligence, Machine Learning.

Introducción

Hoy el mundo se torna cada vez más inestable e impredecible, lo que exige que los responsables de la política económica reflexionen sobre el sistema financiero y su impacto en el mundo globalizado, así como en las diversas dinámicas productivas del mercado. Este análisis es especialmente relevante al abordar un tema tan complejo como los riesgos financieros, sobre los cuales no existe un consenso claro para su estandarización. Además, gestionarlos de manera adecuada sigue siendo un desafío crítico en un entorno económico en constante evolución (Ruza & Curbera, 2013).

En particular, el riesgo de crédito está compuesto por dos factores fundamentales: el riesgo de impago (que tiene que ver con la imposibilidad de cumplimiento con sus deudas presentes y futuras) y la calificación crediticia (que evalúa la capacidad de pago futura y los factores que la afectan). Ambos elementos determinan la probabilidad de incumplimiento (Samaniego, 2008).

En las últimas décadas, numerosas crisis han afectado economías globales: México (1994), Asia (1997), Rusia (1998), Brasil (1998), Turquía (1999), Argentina (2001-02) (Jadresic & Schmidt-Hebbel, 2003), las burbujas puntocom (2000-02), hipotecas subprime (2007-08), deuda europea (2010-12), bancaria en Chipre (2013), petrolera (2014-16) (Gonzales, 2016), criptomonedas (2018, 2022), Covid-19 (2019-22) y un riesgo en economías desarrolladas (2024) (Kenworthy, Kose, & Perevalov, 2024).

Todo esto sugiere un escenario en el que la persona que solicita un crédito podría enfrentar dificultades para cumplir con sus obligaciones financieras. Todo ello apunta a que es crucial determinar el momento, el monto y las causas de potenciales incumplimientos. Por ello, han surgido metodologías, técnicas y herramientas que mejoran la gestión de riesgos crediticios, optimizando la

evaluación y el seguimiento de estos casos hasta la actualidad (Vasicek's, 2015; Servigny & Olivier, 2004).

Los libros de administración financiera suelen abordar la gestión del endeudamiento comenzando con las 5Cs. Este es un modelo clásico que resume los principios fundamentales de la política crediticia. La primera C hace referencia a la capacidad de pago de la empresa y su historia financiera. La segunda refiere al apalancamiento de la empresa y a la solvencia de la misma. La tercera considera la estabilidad de la empresa para poder responder ante deudas y eventualidades. La cuarta es colateral, refiere al respaldo de la deuda y la capacidad de poder convertir el efectivo. La última C tiene que ver con el ciclo, ya que regularmente las condiciones de la economía no son siempre las mismas (Gómez & Checo, 2014).

Metodología

El trabajo se presenta bajo las secciones detalladas a continuación. La primera sección analiza el estudio del riesgo de crédito, se centra en evaluar la probabilidad de que un deudor incumpla con sus obligaciones financieras, lo que puede generar pérdidas para la entidad acreedora. Este riesgo se clasifica en distintos tipos, como el riesgo de default, de migración crediticia y de concentración. Posteriormente, se presentan los Acuerdos de Basilea que establecen estándares internacionales que regulan los requisitos de capital y promueven la estabilidad del sistema financiero. Finalmente, para la medición del riesgo se emplean diversas técnicas y modelos, entre los que destacan los métodos paramétricos (basados en distribuciones estadísticas conocidas), no paramétricos (libres de supuestos distribucionales), semi-paramétricos (combinación de ambos enfoques) y modelos de aprendizaje automático, que permiten un análisis más flexible y adaptativo de los datos crediticios.

Riesgo de crédito

Los modelos de evaluación de riesgo crediticio han evolucionado desde técnicas tradicionales hasta enfoques avanzados que equilibran complejidad y parsimonia. Estos puntos centrales se muestran en la Ecuación 1.

Ecuación 1

$$RC = PD \cdot ED \cdot PI \cdot (1 - R)$$

Donde:

RC se define como riesgo de crédito.

PD es la probabilidad de default.

ED la exposición al default.

PI la pérdida de incumplimiento.

R es la tasa de recuperabilidad.

La definición de riesgo de crédito está muy relacionada a la inclusión financiera. Es

un proceso que busca garantizar que la mayoría de las personas que necesiten servicios financieros puedan acceder a ellos en condiciones apropiadas, de forma responsable y adecuada (Delgado, 2022; Ghosh, 2015; Artzner, Delbaen, Eber, & Heath, 2001).

El riesgo de crédito está estrechamente ligado al concepto de inclusión financiera. La inclusión financiera garantiza acceso a servicios financieros en condiciones adecuadas y responsables para quienes los necesitan (Chaudhuri & Cheral, 2012). Su evaluación depende de factores cuantitativos y cualitativos, los cuales se muestran en la [Tabla 1](#). La evolución en su análisis refleja el avance del pensamiento financiero y se adapta a una comprensión más profunda del fenómeno mediante modelos que equilibran precisión y pragmatismo (Samaniego, 2008; Borrero & Bedoya, 2020).

Tabla 1. Factores cualitativos y cuantitativos según Samaniego

Factores	Descripción
Probabilidad de incumplimiento	<ul style="list-style-type: none"> Retraso en el pago más de un mes Retraso en el pago más de 3 meses Suspensión de pagos Quiebra Otros El incumplimiento que contiene la calidad crediticia la contraparte, la tasa de interés influenciada por la probabilidad acumulada, absoluta y condicionada.
Exposición	<ul style="list-style-type: none"> Tipo de instrumento de financiamiento Tiempo del financiamiento Las condiciones del mercado para la tasa de interés La calidad crediticia de la contrapartida
Severidad o pérdida debido al incumplimiento tras el proceso de recuperación (default)	<ul style="list-style-type: none"> Costos de recuperación actualizados Cantidad finalmente recuperada Duración del tiempo de recuperación Tipo de interés para la actualización Definición de incumplimiento Calidad crediticia Ciclo económico Condiciones del mercado Existencia de garantías y colaterales

La categorización propuesta por Knop, Ordovàs, & Vidal (2013) se detalla en la [Tabla 2](#).

Tabla 2. Clasificación del riesgo de crédito por Knop et al

Tipo de riesgo	Descripción
Contrapartida	Es el riesgo más común originado porque una de las partes no puede cumplir con sus obligaciones, lleva a elevar la mora al resto de los agentes económicos.
Emisor	Generalmente se presenta en el mercado bursátil, es producto del emisor de la deuda. El rating es afectado por la insolvencia de este.
País	Se da en los países cuando tienen la probabilidad de incumplir sus obligaciones. Es un indicador para calificar el rating de los bonos soberanos.
Liquidación	Es aquel riesgo que se llega a incumplir cuando una de las partes está en una situación desfavorable como es el caso de una bancarrota.
Calidad crediticia	Está referenciada a la capacidad que tiene una entidad para honrar su deuda y el riesgo que conlleva invertir en este pasivo.

Como enfoque complementario, Rayo (2024) presenta la clasificación desarrollada en la [Tabla 3](#).

Tabla 3. Clasificación del riesgo de crédito por Salvador Rayo.

Tipo de riesgo	Descripción
Individual	Riesgo de solvencia (un solo deudor).
Cartera	Los riesgos asociados a un portafolio de activos financieros, la concentración de activos financieros en un solo sector, entre otros.
Clasificación	Cuando el emisor llega a cambiar su calificación crediticia.

La inclusión financiera se categoriza en función de los recursos y criterios prioritarios, garantizando acceso adaptado a diversos segmentos de la población (Benavente & Porter, 2014). La calificación crediticia tradicional se basaba en cuatro pilares:

- La puntualidad en pagos (o existencia de incobrables) que mide la disciplina financiera.
- El monto adeudado, indicador de sobreendeudamiento.
- El historial crediticio (tiempo y volumen de operaciones) que refleja la experiencia crediticia.
- El intervalo entre nuevos créditos, señal de dependencia al financiamiento.

Aunque estos criterios eran la base del análisis, actualmente han sido complementados con modelos más avanzados que

incorporan variables conductuales y macroeconómicas para una evaluación más precisa del riesgo.

Riesgos de crédito en las familias

El riesgo de crédito surge de diversos factores que afectan a las familias, genera dificultades para honrar deudas, posterga la adquisición de activos y reduce el patrimonio familiar. Esto ocasiona disminución del rendimiento laboral y la necesidad de contraer nuevas deudas para cubrir obligaciones vencidas, todo lo cual termina por perpetuar el ciclo de endeudamiento (Balanta, 2024).

De igual manera, el crédito bancario permite a las familias financiar gastos, con base en ingresos futuros esperados, suavizando así su consumo a lo largo de su ciclo vital. Sin embargo, esta herramienta exige una gestión

rigurosa por parte de las entidades financieras, ya que a mayor plazo del crédito, mayor es el riesgo de incumplimiento. Además, en las familias genera una fuerte dependencia del acceso al crédito para sostener su crecimiento y bienestar económico (Martínez & del Rio, 2004).

Riesgo de crédito en las empresas

Los estudios indican que el endeudamiento empresarial surge por factores macroeconómicos como inflación, deuda pública y rentabilidad bursátil. Sin embargo, según la teoría tradicional y las proposiciones de Modigliani-Miller (MM), a nivel microeconómico su estructura óptima depende del equilibrio entre financiamiento propio y externo. Estos enfoques, junto con aportes de la teoría contemporánea de la firma, guían la gestión financiera para maximizar eficiencia y minimizar riesgos (costos de agencia y costos de transacciones) (Velásquez, 2023).

Como lo asevera Chorafas (2000), en las empresas el riesgo crediticio es la probabilidad de que la empresa incumpla total o parcialmente con sus obligaciones financieras, ya sea por quiebra u otros motivos. Todo lo cual afecta el repago de deudas o rendimientos pactados.

Según Tavera (2014), se identifican seis factores clave que inciden en el riesgo crediticio: morosidad del cliente o sus deudores, quiebra de la empresa cliente, insolvencia económica, sobreendeudamiento, manipulación de estados financieros y garantías insuficientes. Esto se convierte, a su vez, en un desafío y en una oportunidad. Un ejemplo de ello es la gestión de riesgos y la implementación de ISO 31000 que, de una u otra forma, ayudan a identificar, evaluar y mitigar los riesgos que puedan afectar sus objetivos y operaciones. Esto es especialmente relevante en el ámbito financiero, ya que puede implicar pérdidas económicas significativas y un deterioro de la reputación crediticia (Isotools, 2023).

Para ello, las empresas buscan dos tipos de análisis para poder gestionar mejor el riesgo de crédito. El primero es el análisis cualitativo en las empresas, el mismo está compuesto por un conjunto de premisas técnicas que son utilizadas para conocer el modo de proceder del cliente y el entorno que lo condiciona. El segundo es el análisis cuantitativo, este es un estudio más profundo que buscan explicar aspectos centrales del crédito. Las características de ambos análisis se muestran en la Tabla 4.

Tabla 4. Características de los análisis según Tavera (2014)

Categoría	Análisis cualitativo	Análisis cuantitativo
Características	<ul style="list-style-type: none"> • Año de funcionamiento • Tipo de sociedad • Análisis del negocio/sector • Historial crediticio • Performance empresarial (gestión, contabilidad, marketing, política) 	<ul style="list-style-type: none"> • Capital de trabajo • Estados financieros • Índices económicos/financieros • Flujo de caja proyectado • Modelo Z-Score de Altman
Objetivo	Evaluar contexto operativo, reputación y riesgos no financieros.	Medir capacidad de pago, estabilidad financiera y probabilidad de default.

Para las instituciones financieras esto es fundamental de forma especial. En el caso de las empresas y los bancos, existen modelos de riesgo de crédito desarrollados por el Comi-

té de Supervisión Bancaria de Basilea (Banco de Pagos Internacionales, 2015).

Las normas financieras siguen evolucionando. Las recientes crisis han impactado el

crédito y la liquidez, obligando a EE.UU. y la UE a implementar rigurosamente los lineamientos establecidos en Basilea IV para 2025. Se prevé que esto afecte especialmente a los bancos con más de \$100 mil millones en activos, según un resumen de Moody's (2023). Las mejoras introducidas tras las deficiencias identificadas en Basilea III han dado lugar a nuevos cambios, los cuales impactan en:, mismos:

- La revisión del enfoque estandarizado (SA) y en el método basado en calificaciones internas (IRB) para la gestión del riesgo crediticio.
- El riesgo de ajuste de valoración crediticia (CVA).
- El riesgo operacional.
- El marco de ratio de apalancamiento.
- Un nuevo piso de capital basado en SA más ajustado al riesgo (Hait, 2023).

Los Acuerdos de Basilea y el riesgo de crédito

Los Acuerdos de Basilea establecen estándares internacionales para gestionar y regular eficientemente el riesgo de crédito bancario, los cuales se presentan a continuación (Caruana & Narain, 2008).

Acuerdo de Basilea I: se desarrolla el concepto de riesgo de crédito, así como el desarrollo del método estandarizado.

Acuerdo de Basilea II: se puntualiza en tres pilares, los requerimientos mínimos de capital, revisión de la entidad supervisora y el desarrollo del método de calificaciones internas en vez de los autoimpuestos. Sigue el método del cálculo estandarizado (mejorado), el método de calificaciones internas (IRB) y los requerimientos mínimos de capital.

Acuerdo de Basilea III: Busca fortalecer el capital, tanto en cantidad como en calidad. También propone una mayor reserva de capital, conocida como colchón de conservación del capital, para hacer frente a un mayor creci-

miento económico y al desarrollo de posibles burbujas financieras.

Además, se plantean medidas para evitar el riesgo sistémico. Se promueve el desarrollo de ratios de cobertura de la liquidez (LCR) y de financiación neta estable (NSFR). Otro objetivo es mejorar la gestión del riesgo en lo referente a la supervisión. Finalmente, se busca una mayor transparencia en la información financiera. El método más usado es el método estándar, el método de calificaciones internas con las mejoras establecidas líneas arriba y el método de calificaciones internas avanzado (Álvarez, Lochmüller, & Osorio, 2011).

Acuerdo de Basilea IV: su objetivo es restaurar la credibilidad del sistema financiero y el procedimiento de esos cálculos. Restringe el uso de los modelos de calificaciones internas y aspectos de riesgo de crédito de contraparte. Basilea IV postula la modificación de los cálculos de capital para todos los tipos de riesgo. Limita el uso del método IRB avanzado (A-IRB) con carteras de bajo incumplimiento y elimina el método de calificaciones internas por el método estandarizado revisado para los riesgos de ajuste de riesgo de crédito en derivados (CVA).

Se debe revisar el método estándar (SA) utilizado para evaluar el riesgo de que un prestatario no cumpla con sus obligaciones de pago. Además, se eliminan los métodos de medición avanzada (AMA).

En cuarto lugar, se introduce un 'piso de producción' con el objetivo de garantizar que los activos ponderados por riesgo (RWA), calculados mediante modelos internos, no sean inferiores al 72.5 % de los RWA obtenidos con el método estándar (SA), en función del tipo de préstamo o activo y el monto de exposición.

Por último, se establece un 'colchón' adicional en el ratio de apalancamiento para aquellas instituciones financieras consideradas sistémicamente importantes a nivel global (G-SIB), cuya quiebra podría desencadenar una crisis financiera mundial. Asimismo, se

incorpora un 'colchón' de capital de nivel 1, equivalente al 50 % del colchón de capital ponderado por riesgo, para hacer frente a posibles escenarios de alto riesgo. Posteriormente, En (Feridun & Özün, 2020).

Técnicas y modelos para la medición del riesgo de crédito

Existen diversas técnicas y modelos para medir el riesgo crediticio, los cuales han evolucionado notablemente. Los Acuerdos de Basilea, impulsados por el Banco Internacional de Pagos, han influido significativamente en este ámbito, estableciendo estándares clave para los organismos reguladores del sistema financiero, especialmente en el sector bancario y otros segmentos económicos. Por ello, cada institución financiera debe desarrollar la capacidad de diseñar, analizar y evaluar sistemas de crédito robustos. Este desafío adquiere mayor relevancia en un contexto de digitalización masiva en el que el manejo de datos se vuelve crítico, destacando el papel fundamental de los analistas de datos para una implementación precisa y eficiente.

Los modelos de riesgo crediticio, clasificados por Ruza & Curbera (2013) incluyen: econométricos, de optimización, sistemas expertos, híbridos (simulación + estimación) y redes neuronales. Según Chatterjee (2016), estos buscan cuantificar el crédito (Basilea I), identificar determinantes del riesgo y predecir morosidad, entre otros objetivos. Cada modelo aporta distintas herramientas para evaluar la solvencia, optimizar decisiones y anticipar impagos, mejorando así la gestión financiera. La elección depende del contexto, datos disponibles y necesidades específicas. Se destacan así los enfoques avanzados (híbridos e IA) por su capacidad para manejar la complejidad y los grandes volúmenes de información.

Simulación de la transición

Cuando el cálculo analítico directo resulta inviable se emplean simulaciones de calificación crediticia basadas en matrices de transición específicas para cada emisor. Estas matrices, como la presentada en la [Tabla 7](#), establecen las probabilidades anuales de migración entre diferentes ratings, incluyendo la posibilidad de default (Arévalo, Aguilar, & Mejía, 2018).

Tabla 7. Matriz de probabilidades de transición por rating

Rating final	AAA	AA	...	CCC	Default
Probabilidad	p^1	p^2	...	p^{c-1}	p^c
Probabilidad acumulada	p^1	$p^1 + p^2$...	$\sum_{i=1}^{c-1} p_i$	1

Se muestran en la [Tabla 8](#). La generación de la serie de valores aleatorios en las que cada vector de transición sigue una distribución normal estándar $z, N\left(z, \sum_{i=1}^x p_i\right)$, donde

se pueden generar números aleatorios en las que se asigna una calificación específica en función a los límites establecidos (Arévalo, Aguilar, & Mejía, 2018).

Tabla 8. Construcción de la matriz

Lím. Min.	$-\infty$	Z_1	Z_2	Z_3	Z_4	Z_5	Z_6	Z_7
Lím. Máx.	Z_1	Z_2	Z_3	Z_4	Z_5	Z_6	Z_7	$+\infty$
Spread Min	S_1	S_2	S_3	S_4	S_5	S_6	S_7	$S_8 = 0$
Spread Máx.	S_1	S_1	S_2	S_3	S_4	S_5	S_6	S_7
Rating Asoc.	<i>Default</i>	<i>CCC</i>	<i>B</i>	<i>BB</i>	<i>BBB</i>	<i>A</i>	<i>AA</i>	<i>AAA</i>
ID Rating	CR_1	CR_2	CR_3	CR_4	CR_5	CR_6	CR_7	CR_8

Esto permitirá obtener una tabla para cada vector fila $r_i \in \mathfrak{R}$, agregando a ello la matriz de transición y el emisor i y construir los vectores columna de spread SF_i y rating RS_i . Estos se definen en la Ecuación 2.

Ecuación 2

$$SF_{i,j} = S_{min} + (S_{máx} - S_{min}) \frac{(z_{i,j} - z_{min})}{(z_{máx} - z_{min})}$$

Donde:

$$\forall j = \{1, 2, \dots, L\} \text{ y } z_{min} < z_{i,j} \leq z_{máx}.$$

Entonces $RS_{i,j} = CR_x$, si $z_{min} < z_{i,j} \leq z_x$.

$$K01_i = \begin{cases} PV01_i, & \text{donde el emisor es considerado de 'libre de riesgo'} \\ CR01_i, & \text{en otro caso} \end{cases}$$

La severidad es el proceso de recobro de los flujos favorables que no se pueden recuperar en caso de incumplimiento, los cua-

Ecuación 4

$$\text{Severidad} = \frac{\text{Valor de recuperación} - \text{Gastos de recuperación}}{\text{Valor exposición}} = 1 - \text{Recuperación neta}$$

Para modelar la severidad de las pérdidas crediticias se analizan series históricas de bonos en incumplimiento y casos de morosidad extrema. Los datos se ordenan de mayor a menor severidad y se ajustan a una distribución beta, calculando su valor esperado y varianza para calibrar los parámetros alpha (α) y beta (β) de la función.

Donde la matriz $RS_{i,j}$ incluye a los ratings en la misma estructura de CR_i siendo la mínima CR_1 . Es la calificación de crédito equivalente a una situación de default. Para todo elemento de la matriz RS que no sea default entonces puede asociarse un impacto por migración $\Delta P_{i,j}$.

De manera preliminar el impacto de migración se muestra en la Ecuación 3.

Ecuación 3

$$\Delta P_{i,j} = K_{0,1} \cdot \Delta S_{i,j}, \forall j = \{1, 2, \dots, L\}$$

Donde:

les son influidos por distintas variables (en especial de carácter legales) denotado por la siguiente ecuación:

Este enfoque permite estimar probabilísticamente el porcentaje de pérdida ante default, siendo fundamental para el cálculo del LGD (pérdida dado el incumplimiento) y la gestión integral del riesgo crediticio. Un caso icónico es el presentado por Carty y Libermann, en el que se demostró la relación directa entre la 'Seniority' (prioridad de pago) de los bonos y sus tasas de recuperación ante default.

Donde:

$$\mu = E[x]; \sigma^2 = E[x]^2 - E[x^2].$$

Lo mencionado anteriormente permitirá a conocer el valor para: $\alpha = (1 - \mu) \left[\frac{\mu}{\sigma} \right]^2 - \mu$; $\beta = \frac{\alpha}{\mu} - \alpha$. Donde μ es la tasa de recuperación correspondiente al sector del emisor i y σ_i , su riesgo.

Simulación del incumplimiento

La simulación de incumplimiento es una herramienta fundamental para modelar el riesgo crediticio, permite estimar probabilidades de default para instrumentos individuales y para portafolios completos. Los valores pueden ser cálculos por unidad o por portafolios para un conjunto de números aleatorios BB con número de emisores (filas), L número

de simulaciones (columnas) y VM_i para el valor del mercado utilizando la siguiente expresión: $\Delta P_{i,j} = VM_i(1 - B_{i,j})$. Con esta información se puede calcular la pérdida esperada. La misma que está determinada por la *exposición total* (ET_j), la *probabilidad incondicional anual de incumplimiento* (PD_j) y la *severidad ligada a cada operación* (LGD_j) de todas las operaciones (Knop, Ordovàs, & Vidal, 2013). Donde la pérdida esperada se define como: $\sum_{j=1}^n ET_j * PD_j * LGD_j$.

La pérdida inesperada es una operación más compleja porque se necesita calcular la función de densidad de probabilidad en un agregado. El proceso es complejo computacionalmente, por lo cual, se realiza una simplificación matricial para trabajar de manera individual o a nivel más general para un portafolio. En la [Tabla 9](#) se muestra el cálculo de ambas pérdidas.

Tabla 9. Cálculo de la pérdida inesperada (individual y portafolio)

	Individual	Portafolio
Pérdida esperada	$EL_i = \frac{1}{L} \sum_{j=1}^L \Delta P_{i,j}$	$EL_p = \frac{1}{L} \sum_{i=1}^N \sum_{j=1}^L \Delta P_{i,j}$
Riesgo de crédito	$RC_i = \frac{1}{L-1} \sum_{j=1}^L (\Delta P_{i,j} - EL_i)^2$	$RC_p = \frac{1}{L-1} \sum_{j=1}^L \left[\sum_{i=1}^N \Delta P_{i,j} - EL_p \right]^2$
Cuantil α	$\text{Prob}((\Delta P_i \leq C_{x,i})) = \varphi$	$\text{Prob}((\Delta P_p \leq C_{x,p})) = \varphi$
Credit Var α	$CVaR_i = C_{x,i} - EL_i$	$CVaR_i = C_{x,p} - EL_p$
Contribución al riesgo de crédito	$CRC = \frac{\text{diag}(RC) \cdot \text{Corr}(\Delta P) \cdot RC}{RC_p}$	

El modelo Z-Score de Altman

El modelo Z-Score de Altman es un modelo propicio para poder medir la situación financiera de una empresa de manera específica. Este se convierte en un predictivo de la insolvencia financiera de una empresa y se basa en un análisis estadístico iterativo de múltiple ponderación y discriminación. Con esto

se determina la solvencia de una empresa (Belalcazar & Trujillo, 2016).

Este modelo tuvo su origen con Altman en 1968, quien mediante el análisis de datos contables desarrolló un enfoque multivariado para anticipar riesgos de insolvencia (Altman, 1968). Inicialmente fue diseñado para empresas industriales cotizadas en bolsa. El modelo evaluaba cinco categorías clave: liqui-

dez, rentabilidad, apalancamiento, solvencia y actividad (Roque & Caicedo, 2022). El modelo se presenta en la Ecuación 5.

Ecuación 5

$$Z = 1.2X_1 + 1.4X_2 + 3.3X_3 + 0.6X_4 + 0.99X_5$$

Donde:

$X_1 = \frac{\text{Activo corriente} - \text{pasivo corriente}}{\text{Activos totales}}$ es el ratio de liquidez.

$X_2 = \frac{\text{Utilidades retenidas}}{\text{Activos totales}}$ el ratio de rentabilidad acumulada.

$X_3 = \frac{\text{Utilidades antes de intereses e impuestos}}{\text{Activos totales}}$ el ratio de rentabilidad.

$X_4 = \frac{\text{Valor de mercado del patrimonio}}{\text{Pasivo total}}$ es el ratio de estructura financiera.

$X_5 = \frac{\text{Ventas}}{\text{Activo total}}$ es la tasa de rotación del capital.

En 1977 Altman, Haldeman y Narayanan propusieron un modelo con siete variables. Sin embargo, en 1983 Altman realizó la mejora denominada Z' , para empresas privadas, en la que la variable X_4 se reemplaza por el valor de mercado a capital contable. Esta mejora ha tenido otras variantes (para mayores detalles consultar Cindik & Armutlulu (2021)

Modelo KMV de monitoreo de crédito

El KMV (Kecholfer, McQuown, Vasicek) de Moody's desarrollado por Vasicek (1984) y perfeccionado por McQuown (1993) y Kealhofer (1993) amplía el enfoque de Merton, utilizando como insumo clave la estimación de la probabilidad de incumplimiento empresarial (Zapata C., 2021). Fue una expansión desarrollada por la calificadora Moody's que recoge las ideas del modelo de *Frecuencias de incumplimiento esperado* conocida como una función de la

estructura del capital de una empresa, la volatilidad del rendimiento esperado de los activos y su valor actual (Saavedra & Saavedra, 2010). A mayor volatilidad más alta es la tasa de retorno de los activos y, por consecuencia, el mercado tiene mayor incertidumbre sobre el valor del negocio de la empresa. El modelo se presenta en la Ecuación 6.

Ecuación 6

$$PV = \frac{FV \cdot (1 + LGD) + FV \cdot LGD(1 - Q)}{1 + i}$$

Donde:

PV es el valor presente de los flujos de efectivo.

FV es el valor futuro de la deuda.

LGD es la severidad de la pérdida.

$1-LGD$ es la tasa de recuperación.

i la tasa libre de riesgo.

Q es la probabilidad de que el emisor incumpla en un año.

Modelos de puntuación crediticia

El modelo mencionado se basa en una ponderación numérica que presenta la solvencia y el historial de crédito de un agente de crédito, utilizando una puntuación entre 300 y 850. Para calcular dicha puntuación existen tres empresas reconocidas calificadoras con un conjunto de variables como: historial de pagos, monto de la deuda, duración del historial crediticio, el comportamiento crediticio reciente, entre otras (Candian, 2024).

Evalúa el riesgo de default mediante puntajes basados en historial crediticio y variables financieras. Transforma datos en probabilidades (puntajes-scoring) de incumplimiento, clasificando clientes por riesgo. Asigna mayores puntuaciones a mejores pagadores, reduciendo subjetividad en decisiones. Es una herramienta estadística estándar aplicable a personas y empresas que optimiza la gestión crediticia (Vargas & Mostajo, 2014).

Para el cálculo del modelo se realiza una agrupación de variables junto con sus

respectivos atributos. Luego, se evalúa cada atributo asignándole un puntaje que permite su cuantificación. Posteriormente, se establece un umbral que relaciona las características evaluadas con las preguntas formuladas al solicitante. En este contexto, los atributos corresponden a las respuestas dadas por el solicitante, las cuales pueden basarse en sus propios datos o en información externa (Dassatti, 2019). Estos modelos constan de seis etapas: la conformación de la base de datos, segmentación de las variables, categorización de los clientes en mora, luego se seleccionan las variables de mayor valor predictivo, seguido por la validación del modelo y la determinación del umbral (Leung, Cheong, Cheong, O'Farrell, &

Tissington, 2008). Una clasificación interesante fue desarrollada por Rodríguez, et al. (2017) en la que se presentan dos tipos de métodos paramétricos y no paramétricos.

Métodos paramétricos

En el ámbito de los métodos paramétricos, la literatura especializada de esta última década refleja que la mayoría de los profesionales en riesgo de crédito considera ampliamente conocidos ciertos modelos como los modelos univariantes (por ejemplo ANOVA, Logit y Probit), los cuales se muestran en la Tabla 10 (Bermúdez, Manotas, & Olaya, 2020).

Tabla 10. Modelos paramétricos univariantes

Método	Descripción	Modelo matemático
ANOVA	El enfoque dado por (Rodríguez, Becerra & Cardona, 2017) destaca la relevancia de cada factor en el riesgo crediticio en dicho análisis.	$F = \frac{MSE_F}{MSE_E}$
Logit (Modelos de Regresión Logística)	Expresan una relación lineal entre la probabilidad de default y las variables explicativas	$G(z) = \Lambda(z);$ $P(y = 1 x = \Lambda) = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k$ $\Lambda(z) = \frac{e^z}{1 + e^z}$
Logit multinomiales	Basilea II definió cinco rangos de maduración con escalas específicas, generando así cinco posibles respuestas (Chaudhuri & Cheral, 2012 en Rodríguez, et al., 2017).	$P_i = \frac{e^{(\alpha + \beta_1 x_{i1} + \dots + \beta_k x_{ik})}}{\sum_k e^{(\alpha + \beta_1 x_{i1} + \dots + \beta_k x_{ik})}}$
Logit mixtos	Estos modelos permiten interpretación económica y pronósticos calibrados, pero su no linealidad limita su capacidad predictiva (Kukuk & Rönberg, 2013).	$P(y_i = 1 x_i, \tilde{\beta}, \tilde{\theta}) = \int_{\beta_i} \Lambda(\alpha + \beta_1 x_{i1} + \dots + \beta_k x_{ik}) f(\beta_i \tilde{\beta}, \tilde{\theta}) d\beta_i$
Modelos Probit, probabilidad logística	Los modelos son no lineales en los parámetros y trabajan bajo el supuesto de una distribución normal, basado en una función.	$G(z) = \Phi(z)G(z) = \Phi(z)$ el cual se denota por: $P(y = 1 x = \Phi) = (\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k)$ $\Phi(z) = \int_{-\infty}^z \left(\frac{1}{2\pi}\right)^{1/2} e^{-u^2/2} du$

Modelos Tobit, probabilidad truncada	En este modelo se utiliza una variable y^* no observable y otra variable observable y , para lo cual se requiere estimar los parámetros de la variable no observable (Amat, 2018).	$(No\ Censurado)E(y y > \tau)] + [P(Censurado)E(y :$ $y_i = \begin{cases} y_i^*, & \text{si } y_i^* > \tau \\ \tau_y, & \text{si } y_i^* \leq \tau \end{cases}$
---	--	---

Los modelos de análisis discriminante se consideran métodos paramétricos. Sirven para poder clasificar: el tipo de personas segmentadas por un determinado crédito, determinar la tasa de recuperación según el tipo de garantía que presente cada crédito, estimar la pérdida esperada y las provisiones de cartera necesarias.

Matemáticamente se dice en q grupos se asigna a una serie de objetos y de p va-

riables medidas sobre ellos (x_1, \dots, x_p) en la que se determinará obtener para cada objeto una lista de puntuaciones (y_1, \dots, y_m) , dada la notación desarrollada por (Marín, 2007). De este modo, se puede descomponer la varianza a fin de conocer la variabilidad dentro de los grupos y entre los grupos, tal como se observa en Ecuación 7.

Ecuación 7

$$Cov(x_j, x_{j'}) = \frac{1}{n} \sum_{k=1}^q \sum_{i \in I_k} (x_{ij} - \bar{x}_{kj}) (x_{ij} - \bar{x}_{kj'}) + \sum_{k=1}^q \frac{nk}{n} (\bar{x}_{kj} - \bar{x}_{j'}) (\bar{x}_{kj'} - \bar{x}_{j'})$$

$$\acute{o}T(x_j, x_{j'}) = D(x_j, x_{j'}) + E(x_j, x_{j'})$$

Donde:

T es la matriz de covarianzas total.

E es la matriz de covarianzas entre grupos.

D es la matriz de covarianzas dentro de los grupos.

La Oficina de Control de la Moneda es utilizada por banqueros y reguladores para medir las reservas disponibles frente a una posible eventualidad de pérdidas (Guerra & León, 2018). Con el paso del tiempo se desarrollaron nuevos modelos, razón por la cual se hizo una revisión para poder actualizar las ponderaciones ante el primer Acuerdo de Basilea para el año 1999. Este último tenía algunas incoherencias, razón por la que se busca mejorar los primeros modelos propuestos, dada la complejidad que va adquiriendo el sistema (Saavedra & Saavedra, 2010).

El modelo del grado de solvencia (o modelo de rating) consiste en diez niveles para poder estimar con mayor certidumbre el diferencial (*spread*) a la hora de determinar un préstamo y clarificar mejor a los deudores (bonos) (Knop, Ordovàs, & Vidal, 2013). Los ratings del bono van desde la calificación AAA

como casi nulo riesgo (alta confianza por el organismo emisor) hasta una calificación D (denotada por quiebra e incumplimiento con una muy escasa probabilidad de recuperación del crédito).

Por otro lado, la pérdida esperada permite cuantificar una fracción de la pérdida total (exposición). Esta es útil para saber cuánto se puede perder en un crédito otorgado, el cual se puede expresar como: $P \cdot E = P \cdot I \cdot \text{cuantía del préstamo} \cdot (1 - \text{Tasa de recuperación})$. Sin embargo, este concepto no es muy alentador y puede ser perfeccionado por la pérdida inesperada por $P \cdot Inesp = \sigma_{\text{tasa de incumpl}} \cdot \text{cuantía del préstamo} \cdot (1 - \text{Tasa de recuperación}) \cdot C$. Donde C es un parámetro a estimar influido por el intervalo de confianza.

Los modelos estructurales son la estimación de la probabilidad de incumplimiento, como en líneas anteriores se ha tratado de mostrar a través de varios métodos para la medición del riesgo de crédito (Cabrera, Segovia, & Mariño, 2019). Con el tiempo, los modelos han ido mejorando.

Estos parten del supuesto de que los inversores tienen información completa sobre el mercado, así como un conocimiento total del valor de los activos y de la deuda de todas las empresas..

Aunque este supuesto es bastante estricto, aún queda mucho por avanzar en este campo los modelos (Caicedo, Claramunt, & Casanovas, 2011).

El modelo de Merton supone un mercado perfecto, sin fricciones, con una estructura de tasas plana y conocida. Asume que el valor de la firma no depende de su estructura de capital, permite libre elección de financiamiento y que los activos siguen un movimiento browniano geométrico. Este enfoque valora el riesgo crediticio considerando la deuda como una opción sobre los activos de la empresa, siendo clave en la evaluación de default.

Una extensión de dicho modelo es el Black Sholes. Esta amplió el análisis de reclamaciones contingentes, la deuda de una empresa se considera como una reclamación de activos donde (V_a) es el valor de los activos que siguen un movimiento browniano geométrico. *m.Bg*

Donde:

μ es el rendimiento promedio.

σ_A es la volatilidad para un proceso estándar de Wiener.

W_t , para una distribución normal tipificada.

(Z) define en un espacio de probabilidad.

((Ω, \mathcal{F}, P)) con una filtración (\mathcal{F}_t) $_{t \in [0, T]}$.

El mismo se representa como: $dV_A = \mu_A V_A dt + \sigma_A dW_t$, el cual se puede logaritmizar y la expresión se puede transformar en:

$$\ln V_A = \ln V_0 + \left(\mu - \frac{1}{2} \sigma_A^2 \right) t + \sigma_A Z \sqrt{T}.$$

Donde:

El Valor total de los activos está representado por el valor de mercado de las acciones de la empresa (V_e).

El valor de su deuda por la emisión de un bono cupón cero, el cual por simplicidad puede escribirse de la siguiente forma: $V_D = \max(V_A - V_D, 0)$.

La misma que V_e asume el comportamiento de una opción de compra de tipo europea, ya que si el valor de los activos es insuficiente para cumplir con la deuda, entonces los accionistas no ejercerán su derecho y dejarán la empresa a sus acreedores.

La probabilidad de incumplimiento de la empresa está dada por $p(t, T) = p[V_A \leq V_D] = p[\ln V_A \leq \ln V_D]$ y en ausencia de riesgo el valor de V_e asume el siguiente comportamiento de la fórmula $V_E = V_A N(d_1) - V_D e^{-rT} N(d_2)$. Se distribuye de manera aleatoria dado los parámetros d_1 y d_2 , donde:

$$d_1 = \frac{\ln\left(\frac{V_A}{V_D}\right) + \left(r + \frac{1}{2}\sigma_A^2\right)T}{\sigma_A \sqrt{T}}; d_2 = d_1 - \sigma_A \sqrt{T}$$

Por lo que la probabilidad de incumplimiento es aquella que esté bajo el área de la curva: $p[V_A \leq V_D]$, la cual es un proceso difuso (Caicedo, Claramunt, & Casanovas, 2011).

El modelo KMV de Moody's es un modelo que tiene aspectos sustanciales como la estimación de la probabilidad de impago de un prestatario, ratios financieras de liquidez y rentabilidad, precio de las acciones, bonos, la volatilidad explícita, las expectativas de solvencia, la utilización de las matrices de transición y algunos otros más, por lo que es un modelo y complejo a la vez (Editores de Mint2Save, 2023).

La expresión asociada a este modelo es:

$$DD = \frac{V_A - DP}{\sigma_A V_A} \text{ ó } DD = \varphi \left(\frac{\ln\left[\frac{V_A}{V_D}\right] - \left(r + \frac{1}{2}\sigma_A^2\right)T}{\sigma_A \sqrt{T}} \right).$$

Donde:

Distancia a Default (DD), ya que es el número de desviaciones típicas en el que debe cambiar el valor del activo V_a con el valor de la deuda V_D para que se produzca insolvencia en un tiempo T a la dificultad para el cálculo σ_A se debe llegar a aproximar $p[V_A \leq V_D] = \mathcal{N}(-DD)$ y φ , conoci-

da como la regla interna de Moody's que asocia a cada empresa una probabilidad de insolvencia, denominada Expected Default Frequency (*EDF*) (Novales, 2017). El cálculo del nivel de endeudamiento se muestra en la Ecuación 8 (que posterior a ello puede llegar a insolvencia), siendo de manera más precisa está debe estar dentro del límite de la deuda de corto plazo con la deuda de largo plazo (Novales, 2017).

Ecuación 8

$$D = ST + 0.5LT \text{ si } \frac{LT}{ST} < 1.5$$

Donde:

ST es la deuda de corto plazo.

LT es la deuda de largo plazo, parte de la regla que establece Moody's.

Este modelo ganó gran popularidad después de Basilea II, ya que se utiliza para la evaluación y gestión del riesgo crediticio en carteras de préstamos e inversiones. También se aplica en la fijación de precios, la calificación crediticia y la asignación de capital. Además, se considera adecuado para esta-

blecer requerimientos de capital y para que las instituciones financieras puedan ejercer una regulación más efectiva Fue m (Editores de Mint2Save, 2023).

El modelo de Vasicek describe tasas de interés con reversión a la media. Mientras el movimiento browniano geométrico modela activos sin tendencia de equilibrio, la ecuación diferencial estocástica asociada es $dA_i = \mu_i A_i dt + \sigma_i A_i dx_i$.

Donde:

El parámetro A_i es el valor de los activos de la i -ésima empresa con las propiedades de una distribución normal $N(0,1)$ en un determinado espacio de tiempo: $A_i(T) = e^{A_{(0)} + \mu_i T - \frac{1}{2} \sigma_i^2 T + \sigma_i \sqrt{T} x_i}$

Se presentará incumplimiento en $A_i(T) < B$, el cual puede expresarse de manera aleatoria $p[A_i(T) < B_i] = p[x_i < c_i] = \mathcal{N}(c_i) = p^*$. El obligado cae por debajo de la distribución normal, cae por debajo de cierto c_i . En otras palabras, es probabilidad de incumplimiento si cae dentro del ciclo. Se expresa rigurosamente en la Ecuación 9.

Ecuación 9

$$\begin{aligned} p[A_i(T) < B_i] &= p[x_i < c_i] = p[x_i < N^{-1}(p^*)] = p[S\sqrt{\rho} + Z_i\sqrt{1-\rho} < N^{-1}(p^*)] \\ &= p\left[Z_i < \frac{c_i - S\sqrt{\rho}}{\sqrt{1-\rho}}\right] = \mathcal{N}\left[\frac{\mathcal{N}^{-1}(p^*) - S\sqrt{\rho}}{\sqrt{1-\rho}}\right] \end{aligned}$$

Por lo que se puede extender a la probabilidad de incumplimiento la cartera que cae en incumplimiento extendida, dada la función de distribución de probabilidad

$p[p(S) \leq x] = p[S \geq p^{-1}(x)] = \mathcal{N}\left[\frac{\sqrt{1-\rho}\mathcal{N}^{-1}(x) - \mathcal{N}^{-1}}{\sqrt{\rho}}\right]$. En sentido inverso esto puede describirse como la probabilidad de incumplimiento condicionado a S , denotado por la Ecuación 11.

Ecuación 11

$$p\left(x_i < c/S\right) = \mathcal{N}\left[\frac{c - S\sqrt{\rho}}{\sqrt{1-\rho}}\right] = \mathcal{N}\left[\frac{\mathcal{N}^{-1}(p^*) - S\sqrt{\rho}}{\sqrt{1-\rho}}\right]$$

El valor de S es un valor no observable. Eso no significa su inexistencia, por el contrario, influye y determina el riesgo crediticio. El mismo puede calcularse mediante filtro de

Kalman, el valor de ρ de las correlaciones variará en sentido inverso a la situación económica y financiera del contexto y, finalmente, el modelo de Vasicek proporcionará un

cálculo directo del riesgo de incumplimiento de una cartera.

El Comité de Basilea II estableció el uso de ponderaciones de riesgo para determinar los requerimientos de capital bajo dos supuestos fundamentales:

1. El tamaño de cada préstamo es pequeño y poco influyente, lo que implica que las carteras deben ser desagregadas asintóticamente para garantizar su despreciableidad.
2. Existe una única fuente de choques comunes denominada factor único asintó-

tico de riesgo (FUAR), condiciones que deben cumplirse de manera irrestricta.

Sin embargo, el segundo supuesto resulta difícil de aplicar en la práctica. Esto se debe a que las carteras, al buscar despreciableidad, tienden a formar nódulos. La formación de estos nódulos reduce la diversificación y, como consecuencia, se requiere una mayor cantidad de capital para constituir una cartera nodular (APR). Esta cartera debe ser calibrada adecuadamente para mitigar dicho efecto (Chatterjee, 2016). La expresión correspondiente se presenta en la Ecuación 12.

Ecuación 12

$$\rho = 0.12 \left[\frac{1 - e^{-50 \cdot PD}}{1 - e^{-50}} \right] + 0.24 \left[1 - \frac{1 - e^{-50 \cdot PD}}{1 - e^{-50}} \right]$$

Donde:

El límite se ídebe encontrar entre el 12 % y 24 % de un 50 % de incertidumbre, dada la probabilidad de default y, así mismo, se busca cuantificar

la severidad (*LGD*) y cuantificar el requerimiento de capital (*K*). Ante un vencimiento efectivo (*M*), para un (β) (Samaniego, 2008). Esto se muestra en Ecuación 13.

Ecuación 13

$$K = LGD \cdot \mathcal{N} \left[\left[(1 - \rho)^{-0.5} \cdot G(PD) + \left[\frac{\rho}{1 - \rho} \right]^{0.5} \cdot G(0.999) \right] - PD \right] \cdot \left[\frac{(1 + (M - 2.5) \cdot \beta)}{(1 - 1.5\beta)} \right]$$

El Modelo CyRCE para mercados emergentes fue diseñado para bancos en economías emergentes. CyRCE vincula riesgo crediticio con capital requerido y límites por segmento. Propone usar VaR (como en riesgo de mercado) para estimar pérdidas potenciales en un intervalo de confianza, permitiendo identificar segmentos riesgosos y optimizar capital. Su enfoque simple, pero general, facilita la adopción y aborda desafíos como la diversificación imperfecta y la formación de nódulos en carteras (Márquez, 2006; Saavedra & Saavedra, 2010).

La distribución de probabilidades que se observa en la Ecuación 14 permitirá calcular el VaR de una cartera de crédito. Los elementos

del riesgo se encuentran parametrizados y, ante cualquier eventual error de cálculo dadas las deficiencias, se pueden subsanar haciendo supuestos.

Ecuación 14

$$\theta \leq \frac{(\Psi - p)^2}{Z_\alpha^2 p(1 - p)} = \Theta(p, \Psi, \alpha)$$

Donde:

$\psi : \frac{K}{V}$ es la razón de capitalización del banco.

ρ la probabilidad de impago.

Z_α la variable normal estandarizada.

V el valor de una cartera.

f_i el monto del *k*-ésimo crédito de la cartera.

El VaR para una determinada de crédito será: $VaR_\alpha = pV + Z_\alpha \sqrt{p(1-p) \sum_{i=1}^n f_i^2}$ y el Índice de Herfindahl-Hirschman establece los límites de crédito como se muestra en la Ecuación 13.

Ecuación 13

$$\frac{\sum_{i=1}^n f_i^2}{\left[\sum_{i=1}^n f_i\right]^2} \leq \frac{(\Psi - p)^2}{Z_\alpha^2 p(1-p)}$$

Además, la relación de suficiencia de capital se establece como:

$$\Psi \geq p + Z_\alpha \sqrt{p(1-p) \frac{\left[\sum_{i=1}^n f_i^2\right]}{\left[\sum_{i=1}^n f_i\right]^2}}$$

Los modelos activos ponderados por riesgo de crédito se definen por el valor del activo que proporciona el efecto combinado de un factor sistemático y otro denominado idiosincrásico. Cada ente i incumple con sus obligaciones si cada variable aleatoria x_i cae por debajo del umbral, las mismas que se distribuyen normalmente y están equicorrelacionadas, cada valor de cada activo está determinado por: $x_i = S_t \sqrt{\rho} + Z_{it} \sqrt{1-\rho}$.

Donde:

S_t es el componente sistemático y Z_{it} el componente idiosincrásico. Ambos una distribución normal $N(0,1)$

ρ el coeficiente de correlación en una cartera de préstamos donde x_i y Z_{it} son variables aleatorias independientes con distribución normal (Vasicek, 2015 citado en Chatterjee, 2016).

El modelo de correlaciones crediticias se utiliza cuando existen condiciones de impago en diferentes sectores que normalmente diversifican la cartera. Estas variables muestran un aumento simultáneo del riesgo durante condiciones económicas adversas. Una alta correlación entre ellas indica una convergencia en el comportamiento del riesgo. Dicha correlación puede calcularse en distintos intervalos de tiempo, lo que permite evaluar si el régimen crediticio ha pasado de

un estado de 'riesgo activado' a uno de 'riesgo desactivado' (Carruthers, 2023).

Los modelos de cópulas dinámicas sirven para reconocer el índice de morosidad, convirtiéndose en un buen indicador y saber cómo influye en el riesgo de crédito (Martínez, Bucio, & Ortiz, 2021). Se utiliza una serie de funciones marginales, conformadas por el comportamiento de variables económicas que generan una influencia en la función de distribución de probabilidad y describen una estructura de dependencia sobre algún fenómeno aleatorio. Para mayor detalle se puede consultar a Tam (2019) en la que hace una descripción sofisticada de este modelo.

En los modelos Var de Crédito, Π define el valor de una cartera de créditos. Las medidas más comunes para medir el riesgo de crédito son: pérdida esperada (EL), valor en riesgo (VaR), pérdida no esperada (NEL) y el VaR Condicional ($CVaR$) (de Servigny & Olivier, 2004 citado en Téllez, 2010).

La pérdida esperada se denota por EL_i para el i -ésimo activo de una cartera formada por n activos. La pérdida esperada es la suma de las pérdidas esperadas de cada activo que lo conforman, donde $E_{L\Pi} \equiv E(L_\Pi) = \sum_{i=1}^n E_{L_i}$ (Téllez, 2010).

El Valor en Riesgo VaR conocido como nivel de pérdidas en la cartera que será excedido solo el $(1-\alpha)\%$ de las veces en promedio en un horizonte de tiempo anual para un nivel de confianza α , dada una distribución de probabilidad acumulada $F_{L\Pi}(\cdot)$ el cual puede ser denotado matemáticamente $VaR_\alpha = \min\{j \in \mathbb{R} | F_{L\Pi}(\cdot) \geq \alpha\}$. Donde el valor de una cartera persigue una distribución aleatoria en relación con su diferencia Π^0 como un valor de referencia de $\Pi_{1-\alpha}$ en relación con otro valor basado en un intervalo de confianza $VaR_\alpha = \Pi^0 - \Pi_{1-\alpha}$, donde $\Pi^0 \geq \Pi_{1-\alpha}$.

La pérdida no esperada (NEL) es la distribución de pérdidas de la cartera. Se define como la dispersión de las pérdidas alrededor de la pérdida promedio de una determinada

cartera (Servigny & Olivier, 2004 citado en Téllez, 2010) $\sigma_L = E\left\{[L_{II} - E(L_{II})]^2\right\}^{\frac{1}{2}}$ o como la pérdida por encima de la esperada que puede incidir el acreedor por incumplimiento de su contraparte determinada en términos de la desviación estándar donde $k = \frac{\text{VaR}_\alpha - \text{EL}}{\sigma_L}$.

El Capital económico (CE) es similar a la pérdida, sin embargo, se interpreta como el capital necesario por las entidades financieras (reserva) para no caer en insolvencia, dadas las posibles pérdidas al nivel de confianza α denotado por: $\text{CE}_\alpha = \text{VaR}_\alpha - \text{EL}$

El VaR condicional (CVaR) se conoce como la pérdida media en exceso, déficit medio (déficit esperado), la misma que sirve como una extensión del valor en riesgo (VaR), definida por $\text{CVaR}_\alpha = \Pi^0 - E[\Pi | \Pi \leq \Pi_{1-\alpha}]$.

Donde:

$\Pi^0 \geq \Pi_{1-\alpha}$ debe ser considerado como un complemento del VaR bajo una distribución Normal o Gamma.

En la Tabla 11 se muestran los tipos de simulaciones que pretenden cuantificar el riesgo de mercado y pueden adecuarse al riesgo de crédito (López, Chumacero, & Arrojo, 2024).

Tabla 11. Modelos paramétricos univariantes

Simulación	Descripción
Montecarlo	Métodos estadísticos inferenciales y de computación para reproducir, mediante modelos matemáticos, el comportamiento pseudoaleatorio de sistemas reales no dinámicos para eventos discretos o continuos (Alomoto, 2017).
Paramétrica	Técnicas heurísticas que simulan una variedad de parámetros que permiten ajustar, en mejor forma, la función objetiva que minimiza los errores y que pueden reproducir las características esenciales y la dinámica del sistema. Utiliza una realización pseudoaleatoria $\{r^{[1]}, \dots, r^{[m]}\}$ (Holton, 2013).
Histórica	Basilea II definió cinco rangos de maduración con escalas específicas, generando así cinco posibles respuestas (Chaudhuri & Cheral, 2012 en Rodríguez, et al., 2017).

Los modelos de puntaje crediticio (*Credit Scoring*) son fundamentales para evaluar el riesgo crediticio en entidades financieras. Determinan la viabilidad de operaciones y analizan riesgos de financiamiento y liquidez. Permiten identificar vulnerabilidades en clientes (personas/empresas) y diseñar instrumentos que mitiguen dichos riesgos, facilitando una gestión oportuna y efectiva. Su aplicación es clave para decisiones de aprobación y seguimiento de carteras crediticias (Fica, Aranguiz, & Gallegos, 2018). Estos modelos han sido ampliamente estudiados en la literatura y ayudan a las instituciones financieras a cuantificar la tasa de interés que deben cobrar a sus clientes y valorar los portafolios. Su objetivo es definir si un cliente que presenta particularidades \mathbb{X} va a caer en una situación de falla financiera dentro de un futuro cercano y no podrá devolver la totalidad del crédito otor-

gado. $f(\mathbb{X})$ es una función matemática que aproxima la probabilidad $p(y = \text{falla} | \mathbb{X}) = f(\mathbb{X})$ (Fica, Aranguiz, & Gallegos, 2018)

Para el modelo de calificaciones internas los bancos deben clasificar la exposición en libros en cinco categorías generales de activos. Entre ellas tenemos a las empresas, deuda soberana, bancos, cartera minorista y capital accionario. Además, la cantidad de capital regulador depende únicamente de la pérdida no esperada de la cartera (PNE). Este modelo también se conoce como IRBa, desarrolla la gestión del riesgo de las entidades financieras, quienes se responsabilizan de la estimación y en función de su perfil de riesgo (Sotomayor, 2012). Sus componentes son la probabilidad de incumplimiento (PD), la exposición ante el incumplimiento (EAD) y la pérdida dado el incumplimiento (LGD).

Este modelo fue desarrollado en el Acuerdo de Basilea II y se han establecido modificaciones adoptadas por cada institución financiera, ya en el método más avanzado se establecen metodologías propuestas para el cálculo del riesgo operacional y de mercado (Flores, 2012).

El IRB- Método Básico consiste en las instituciones financieras que pueden realizar sus propias estimaciones. *PD* puede estar basado en el uso de su puntuación crediticia y el cumplimiento de los requerimientos exigidos. *EAD* es determinado de manera interna por el saldo a pagar antes del incumplimiento de la deuda y *LGD* se estimada por el Comité de Basilea. En el año 2001 se tomó el valor de *LGD* con 45 % para los préstamos asegurados con un colateral físico no inmobiliario y *LGD* de 40 % para préstamos asegurados por cuentas por cobrar a los clientes dueño del crédito (Sotomayor, 2012).

Para el IRB-Método Avanzado se sugiere que *PD*, *EAD*, *LGD* sean medidas por las instituciones financieras, quienes deben evaluar los riesgos mediante métodos confiables, tanto para el análisis cuantitativo como cualitativo. Los valores para *LGD* deben estar entre 40 %, 45 %, 50 % y 75 %. Para la estimación de la *PD* se realice con el análisis discriminante lineal o modelos Probit, Logit, redes neuronales y árboles de decisión que, de igual forma, se utilizan para puntuación crediticia. Posteriormente, se acordó eliminar este método para ciertas clases de activos, estableciendo 'input floors' (como *PD* y *LGD*) para garantizar un mínimo conservadurismo. El BCBS sugiere reemplazar el modelo IRB, al no ajustarse a la realidad, por un indicador más preciso

que mida mejor el requerimiento de capital por concentración sectorial.

El Comité de Basilea (BCBS) advierte que el riesgo de concentración crediticia – presente desde Basilea II– requiere políticas internas rigurosas para su gestión (García, 2022). Este riesgo se materializa cuando los bancos acumulan exposiciones elevadas hacia una misma contraparte (o grupo vinculado) o concentran operaciones en un sector económico o región específica. Dichas prácticas pueden desencadenar pérdidas críticas, amenazando la estabilidad financiera y la continuidad operativa del banco. Por esto, su monitoreo y mitigación son pilares fundamentales para preservar la solvencia bancaria.

El modelo general para el riesgo de crédito se describe de la siguiente forma. Sea un portafolio de n dado $i = 1, \dots, n$ créditos indexados dada la ponderación por crédito w_i , denotado por: $w_i = EAD_i / \sum_{j=1}^n EAD_j$ dado que son eventos aleatorios se pueden escribir como una distribución Bernoulli $p(D_i = 1)$ y $p(D_i = 0) = 1 - pD_i$, donde la pérdida total del portafolio se puede expresar de la siguiente manera: $L_n = \sum_{i=1}^n EAD_i \cdot LGD_i \cdot D_i$

Donde:

LGD_i es la probabilidad de incumplimiento y se expresa de la siguiente forma: $\mathbb{E}[L_i] = EAD_i \cdot \mathbb{E}LGD_i \cdot pD_i$.

Finalmente, la pérdida de portafolio puede escribirse como:

$$\mathbb{E}[L_n] = \sum_{i=1}^n \mathbb{E}[L_i] = \sum_{i=1}^n EAD_i \cdot \mathbb{E}LGD_i \cdot pD_i$$

El ajuste por granularidad para evaluar el Capital Regulatorio citado por Gordy & Lütkebohmert (2013), como lo citó en García (2022), se muestra en la Ecuación 14.

Ecuación 14

$$GA = \frac{1}{2\mathcal{K}} \cdot \sum_{i=1}^n w_i^2 \left[(\delta C_i (K_i + R_i) + \delta (K_i + R_i)^2 \frac{\sigma^2(LGD_i)}{\mathbb{E}LGD_i^2} - K_i (C_i + 2(K_i + R_i)) \cdot \frac{\sigma^2(LGD_i)}{\mathbb{E}LGD_i^2}) \right]$$

Donde:

GA es ajuste por granularidad.

w_i^2 es el tamaño relativo de la exposición al cuadrado i con respecto al portafolio total.

R_i es la pérdida esperada de la exposición i , K_i el capital requerido según el Acuerdo de Basilea II.

$\sigma^2(LGD_i)$ la varianza de LGD_i de i y C_i es el capital de riesgo requerido denotado como $(\sigma^2(LGD_i) + ELGD_i^2)/ELGD_i^2$.

Los derivados de crédito son instrumentos financieros complejos diseñados para gestionar el riesgo crediticio, permitiendo la transferencia de exposición crediticia entre partes sin necesidad de poseer el activo subyacente. Son utilizados por empresas y gobiernos para cubrir riesgos o especular (Editores de CQF, 2025). Su desarrollo se consolidó a fines del siglo XX con la estandarización de contratos por la ISDA, que definió eventos de crédito como impagos o quiebras (Labanda, 2005). Estos instrumentos se clasifican en: permutas crediticias (*credit swaps*), opciones crediticias (*credit options*) y productos estructurados con derivados de crédito, cada uno con características y aplicaciones específicas en el mercado financiero (Labanda, 2005).

Métodos no paramétricos

Los métodos no paramétricos han avanzado gracias a la inteligencia artificial, aplicada en el análisis de riesgo. Entre las técnicas más utilizadas destacan las redes neuronales, los árboles de decisión y las máquinas de soporte vectorial, como señalan diversos estudios (Borrero & Bedoya, 2020).

Estos modelos adquieren relevancia al facilitar la gestión integral de riesgos, especialmente de liquidez y crédito ante la incertidumbre que enfrentan los gestores financieros. Su capacidad predictiva permite identificar señales tempranas de insolvencia, optimizando así el control de carteras, en particular la exposición a mora. Cabe destacar que, si bien estos sistemas se sustentan en

algoritmos matemáticos complejos, operan como 'cajas negras' que solo requieren el registro de variables de entrada (datos financieros, históricos, entre otros) y generan salidas (indicadores de riesgo) sin revelar su lógica interna. Esta característica exige validación constante para garantizar su confiabilidad en la toma de decisiones estratégicas (Rodríguez, Becerra, & Cardona, 2017)

La inteligencia artificial (IA) es un área multidisciplinaria que tiene como objetivo replicar las capacidades cognitivas humanas en máquinas. Dentro de este campo existen diversas ramas, como el aprendizaje automático (*Machine Learning*, ML), que permiten que las máquinas aprendan y mejoren a partir de datos sin requerir una programación explícita para tareas específicas. Esto se debe a que no dependen de seguir instrucciones predefinidas, sino que pueden adaptarse y evolucionar basándose en la información que procesan (Paramesha, Rane, & Rane, 2024).

Las redes neuronales artificiales se clasifican principalmente en tres categorías según su propósito:

- Redes de aproximación de funciones.
- Redes de aprendizaje de secuencias.
- Redes de clasificación (Mashrur, Luo, Zaidi, & Robles, 2020; Pérez & Fernández, 2007).

Estos modelos han demostrado un desempeño superior en comparación con otros enfoques inteligentes, incluidas diversas técnicas de aprendizaje automático, gracias a su capacidad para resolver problemas complejos en áreas como el procesamiento de lenguaje natural, el análisis de secuencias temporales y el procesamiento de imágenes y videos. En particular, se anticipa que su impacto en el campo de la criptografía será significativamente mayor en comparación con los métodos tradicionales de aprendizaje automático (Wolpert & Macready, 1997; Sarker, 2021; Leijnen & Veen, 2020). Matemáticamente, se

define como función de red de una neurona $f(x)$ de una función compuesta de $g_i(x)$, dado por una ponderación w_i y una función de activación k , de modo que se puede expresar de la siguiente forma $f(x) = k\left(\sum_i w_i g_i(x)\right)$.

El aprendizaje profundo (*Deep Learning*, *DL*) es una rama avanzada del aprendizaje automático que emplea redes neuronales artificiales con múltiples capas para abordar tareas complejas como el reconocimiento de imágenes. Estas redes neuronales profundas están inspiradas en la estructura del cerebro humano y están diseñadas para procesar y aprender de grandes volúmenes de datos, identificando patrones y características de forma autónoma. Su capacidad para extraer información relevante y realizar inferencias sofisticadas las convierte en una herramienta poderosa para resolver problemas en diversos campos (Zahidur, 2024).

La clasificación de las redes neuronales depende de cómo se conectan sus capas

ocultas, es decir, de su arquitectura y de la capacidad de ciertas células para retroalimentarse o ejecutar operaciones de convolución. Entre los tipos más destacados se encuentran las redes neuronales convolucionales (CNN), las redes neuronales recurrentes (RNN), las redes de memoria a largo y corto plazo (LSTM), las redes generativas adversarias (GAN), las redes autocodificadoras y las redes transformadoras. Cada una de estas arquitecturas está diseñada para resolver tareas específicas y aprovechar diferentes características de los datos, lo que las hace adecuadas para aplicaciones particulares (Zahidur, 2024).

En la [Tabla 12](#) se muestran algunas de estas arquitecturas de redes neuronales comunes, para facilitar la comparación entre modelos. Cabe señalar que el tamaño de un modelo depende en gran medida de la naturaleza del problema en cuestión (Oketunji, Anas, & Saina, 2023).

Tabla 12. *Arquitectura de redes neuronales comunes*

Tipo de red	Objetivo	Arquitectura	Ventajas	Desventajas	Aplicaciones
CNN (Convolutional Neural Networks)	Procesamiento de imágenes y visión por computadora	Capas convolucionales y de pooling	Extracción de características espaciales	Limitada para datos no espaciales	Reconocimiento de imágenes, detección de objetos
RNN (Recurrent Neural Networks)	Procesamiento de secuencias (texto, series temporales)	Conexiones recurrentes entre neuronas	Manejo de secuencias y dependencias temporales	Dificultad para capturar dependencias a largo plazo	Traducción automática y predicción de series temporales
LSTM (Long Short-Term Memory)	Mejorar el manejo de dependencias a largo plazo en secuencias	Variante de RNN con células de memoria	Captura de dependencias a largo plazo en secuencias	Mayor complejidad computacional	Procesamiento de lenguaje natural y predicción de secuencias
GAN (Generative Adversarial Networks)	Generación de datos sintéticos (imágenes, texto, entre otros)	Dos redes: generadora y discriminadora	Generación de datos realistas y creativos	Inestabilidad durante el entrenamiento	Generación de imágenes, arte y superresolución
Autocodificadoras (Autoencoders)	Reducción de dimensionalidad y reconstrucción de datos	Codificador y decodificador	Compresión y reconstrucción eficiente de datos	Riesgo de sobreajuste si no se regulariza	Detección de anomalías y reducción de ruido
Transformadoras (Transformers)	Procesamiento de secuencias y lenguaje natural	Atención multi-cabeza y capas <i>feed-forward</i>	Manejo de contextos largos y paralelización eficiente	Requiere grandes cantidades de datos y recursos	Traducción automática, modelos de lenguaje (ej. GPT o BERT)

El procesamiento del lenguaje natural (NLP) es una rama de la inteligencia artificial que permite a las máquinas comprender, interpretar, generar y responder al lenguaje humano en función del contexto, las emociones y los matices. Para lograrlo, las máquinas se entrenan con grandes volúmenes de datos lingüísticos, aprendiendo patrones y estructuras del lenguaje. Esto incluye el análisis sintáctico, semántico y pragmático. Además de comprender, el NLP permite a las máquinas generar textos, traducir idiomas y mantener conversaciones, sin embargo, siguen existiendo desafíos como la ambigüedad del lenguaje y las variaciones en el habla (Xu, y otros, 2024).

Las ontologías son representaciones estructuradas del conocimiento que definen conceptos, relaciones y propiedades dentro de un dominio específico, permitiendo organizar y compartir información de manera coherente. Una ontología establece un marco de trabajo para entender un conjunto de datos, definiendo qué entidades existen y cómo se relacionan entre sí. Es parte de la inteligencia artificial, la web semántica y la gestión del conocimiento, además de facilitar la interoperabilidad entre sistemas y la extracción de información precisa (Ghidalia, Narsis, Bertaux, & Nicolle, 2024).

La lógica difusa, por otro lado, es un enfoque matemático que extiende la lógica clásica y permite manejar conceptos imprecisos en lugar de trabajar con valores binarios (verdadero o falso). La lógica difusa permite representar valores intermedios entre 0 y 1, lo que hace posible modelar situaciones en las que las fronteras no son claras. Esta herramienta es especialmente útil en sistemas de control, inteligencia artificial y toma de decisiones, donde se deben gestionar incertidumbres y aproximaciones (Nica, Delcea, & Chirita, 2024).

Los árboles de decisión son un modelo de aprendizaje automático que se utiliza para tomar decisiones o hacer predicciones. Estos

se representan como una estructura de árbol en la que los nodos internos son condiciones sobre características del conjunto de datos y las hojas indican la decisión final. El proceso comienza en el nodo raíz y se divide recursivamente según las características, hasta llegar a una clasificación final. Los árboles de decisión son fáciles de interpretar, pero pueden sobreajustarse si no se controlan adecuadamente.

Los árboles de regresión (CART) se hicieron populares en los años setenta del siglo anterior. Consisten en realizar una clasificación binaria con características del modelo clásico univariante y las propias de los sistemas multivariantes. Separan las observaciones de una muestra, asignándolas a grupos preestablecidos de modo que se minimice el coste esperado de los errores cometidos (Bonilla, Olmeda, & Puertas, 2003). Estos modelos presentan una gran flexibilidad y ausencia de supuestos estadísticos con relación a distribuciones de probabilidad o formas funcionales. Sin embargo, el no requerir estimar parámetros ni probabilidades de impago los hace dificultar su comprensión (Seijas, Vivel, Lado, & Fernández, 2017)

Las máquinas de soporte vectorial (SVM) son modelos de aprendizaje supervisado muy efectivos, aplicables a la clasificación y a la regresión. Su principal objetivo es encontrar un hiperplano en el espacio de características que separe las clases de datos de manera óptima, maximizando la distancia entre los puntos más cercanos de cada clase, conocidos como vectores de soporte. Cuando una SVM trabaja en clasificación, busca el límite de decisión que separe las clases lo mejor posible. Cuando se utiliza una SVM para regresión, su objetivo es encontrar una función que prediga los valores de salida más cercanos a los reales, manteniendo un margen de error controlado.

Matemáticamente se puede estructurar de la siguiente manera: $y(x) = \text{sign}(w^T x + b)$.

En la que se identifican dos posibles respuestas de discriminación:
$$\begin{cases} w^T x + b \geq +1, \text{si } y_k = +1 \\ w^T x + b \leq -1, \text{si } y_k = -1 \end{cases}$$

Donde:

y_k es un valor de $[-1 \text{ o } 1] \in \mathbb{X}$, para w^T un vector normal en el hiperplano. El mismo se puede dividir en máquinas de soporte vectorial con aprendizaje supervisado y no supervisado.

La regresión logística es una técnica estadística que se utiliza para modelar la probabilidad de una variable categórica dependiente (generalmente binaria) en función de una o más variables independientes. A diferencia de la regresión lineal, que predice valores continuos, la regresión logística predice la probabilidad de que algo ocurra (como si un correo electrónico es spam o no, si un cliente comprará un producto o no o si un paciente tiene una enfermedad o no).

Aplicaciones del aprendizaje automático en riesgo de crédito

En años recientes, el incremento de activos improductivos y casos de fraude ha hecho imperativo que las entidades financieras implementen sistemas robustos para predecir el desempeño crediticio. Paralelamente, el auge de la inteligencia artificial, particularmente el aprendizaje automático (ML), ha revolucionado este campo gracias a la mayor accesibilidad y gestión de datos. Esta convergencia ha posicionado al ML como herramienta clave en la evaluación moderna del riesgo crediticio, permitiendo análisis más precisos y decisiones mejor fundamentadas ante escenarios financieros complejos (Hermiteño, 2022), sin embargo, no todos los modelos de IA son populares para evaluar el riesgo de crédito.

Existen agencias de calificación crediticia y empresas de puntuación de crédito que ofrecen análisis de clientes a los bancos a cambio de una comisión. En la actualidad, los investigadores continúan explorando diversas técnicas de ML para mejorar el nivel de precisión de la evaluación del riesgo cre-

diticio, asimismo existen técnicas de IA no basadas en ML para evaluar dicho riesgo, las más utilizadas son las basadas en ontologías y lógica difusa.

Los sistemas tradicionales de calificación crediticia suelen basarse en un conjunto limitado de indicadores financieros, lo que puede excluir a solicitantes con historiales crediticios limitados o poco habituales. Por otro lado, los modelos de aprendizaje automático permiten analizar una gama mucho más amplia de datos, lo que puede proporcionar una visión más completa de la situación financiera de una persona. Además, el comportamiento en redes sociales puede revelar información sobre la estabilidad financiera y los hábitos de gasto, como la frecuencia con la que se comparten publicaciones sobre compras o viajes (Le Quy Tai & Giang Thi Thu Huyen, 2019; Hayashi, 2022).

De manera similar, el análisis de los patrones de transacciones, como los movimientos de las cuentas bancarias y tarjetas de crédito, pueden revelar información valiosa sobre ingresos, gastos y capacidad de pago, incluidos historiales de pagos de facturas y préstamos. Además, los datos recopilados a través de teléfonos inteligentes, como la ubicación, los patrones de comunicación y el uso de aplicaciones, pueden ofrecer información adicional sobre el comportamiento y el estilo de vida de una persona, lo que puede ser relevante para la calificación crediticia.

Otra estrategia importante que se utiliza para evaluar el riesgo de crédito es el análisis predictivo, ya que permite identificar y evaluar los riesgos financieros, aprovechando los datos históricos y los algoritmos avanzados para descubrir patrones y anomalías que puedan indicar amenazas potenciales. Técnicas como las redes neuronales, los árboles de decisión y las SVM se emplean habitualmente para modelar y predecir factores de riesgo. Gracias a la aplicación de estas técnicas, las empresas pueden mejorar su capacidad para detectar

señales de alerta temprana de inestabilidad financiera y abordar de forma proactiva los riesgos emergentes (Zahidur, 2024).

Los árboles de decisión que se utilizan en el riesgo de crédito hacen énfasis en el cálculo de la probabilidad de deterioro de cada crédito y la cuantificación de la pérdida esperada (Cardona, 2004). La idea central está concentrada en calcular pérdida potencial, dada la incapacidad de la contraparte de cumplir sus obligaciones. Podemos observar este cálculo en la Ecuación 15.

Ecuación 15

$$P_E = P_I * S * E$$

Donde:

PI es la probabilidad de incumplimiento.

S es la severidad ante el incumplimiento por parte de los deudores.

E es la exposición del monto de los activos expuestos al incumplimiento (Zapata, 2024).

Los modelos de árboles de decisión tienden a tener la mejor performance en términos de tasas de clasificación, ganando precisión, economía y flexibilidad a la hora que los bancos realizan una comparación de los modelos (Butaru, et al., 2016). La probabilidad de incumplimiento se define como una serie de eventos: si $A_1, A_2, \dots, A_n \neq 0$ y sea *B* un suceso para el que se conocen las probabi-

lidades $P(B|A_i)$, entonces la probabilidad del suceso *B* viene dada por: $P(B) = \sum_{i=1}^n P(A_i) \cdot P(B|A_i)$ (Toledo & León, 2021).

Todo este sistema de 'rating' basado en un sistema de probabilidades de incumplimiento se estructura en una matriz de transición, denotando un conjunto de valores que de una u otra forma puedan asociarse a una probabilidad de un estado de quiebra. De allí que del resultado de la aplicación de la matriz de transición se puedan estimar las probabilidades de que una cartera mutar de estado en consideración con la clasificación crediticia del deudor (Toledo & León, 2021).

Por lo tanto, la probabilidad del deudor debe estar definida como $P_{ij} = X_{ij}/X_i, \forall i, j$, denotado en la matriz de transición para *i* y *j* categorías que se muestra en la Tabla 13.

Entre los algoritmos más efectivos para la detección de fraudes en tarjetas se encuentran las SVM por su capacidad de clasificación como de regresión. Además, son capaces de identificar patrones complejos en datos de alta dimensión, esto ayuda a detectar fraudes avanzados. Las redes neuronales artificiales (ANN), por su capacidad de aprender patrones complejos y adaptarse a nuevas situaciones, las hace ideales para una variedad de aplicaciones en la detección de fraudes, puntualizando en los fraudes de tarjetas de crédito (Al-Shabi, 2019).

Tabla 13. Matriz de transición

Período = <i>t</i>	Eventos	Período = <i>t</i> + 1			
		1	2	...	<i>j</i>
	1	P_{11}	P_{12}	...	P_{1j}
	2	P_{21}	P_{22}	...	P_{2j}
	⋮	⋮
	<i>i</i>	P_{t1}	P_{t2}	...	P_{ij}

La regresión logística se centra en predecir la probabilidad de que ocurra un evento, como una transacción fraudulenta. La capacidad de este modelo para generar probabili-

dades es útil para evaluar el riesgo de fraude en diferentes situaciones.

El Algoritmo C4.5, desarrollado por Ross Quinlan en 1993, eliminó la restricción de que

las características deban ser categóricas al definir dinámicamente un atributo discreto (basado en variables numéricas) que fracciona el valor del atributo continuo en un conjunto discreto de intervalos. C4.5 convierte los árboles de decisión entrenados en conjuntos de reglas 'si-entonces' como parte de una mejora introducida por el autor en la versión posterior denominada C5.r0 (Caballero, López, & Bautista, 2015). Este método consiste en realizar particiones al conjunto de datos de manera iterativa. De esta manera, las particiones serán cada vez más puras, con elementos de una clase para un conjunto de datos (S) y medidas que permitan elegir el mejor criterio del conjunto de datos según la entropía, $E(S) = -\sum_{i=1}^n p_i \log(p_i)$ y la ganancia de la información $IG(S, A) = E(S) - \sum_{i=1}^n \frac{S_i}{S} E(S_i)$

Métodos semi-paramétricos

Existen diversos de métodos para calcular (estimar) la pérdida de incumplimiento (P.I). Regularmente, las entidades financieras utilizan los modelos de regresión logística binaria $G(z) = A(z)$; $P(y = 1|x = A) = (\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k)$, $A(z) = e^z / 1 + e^z$, el cual es usado para calcular el *scoring* crediticio del modelo (Bermúdez, Manotas, & Olaya, 2020). Los modelos semi-paramétricos son conocidos también como modelos híbridos aplicados al riesgo de crédito, se han utilizando importantes cantidades de datos extensos y se han desarrollado diferentes modelos híbridos con el uso de los métodos estadísticos tradicionales y de inteligencia artificial moderna. Para ello, autores como Chi, Uddin, Ying, Rashidul, & Iqbal (2020) afirman que con los enfoques de selección de características de clasificación y agrupamiento

Claves esenciales de Basilea IV

Basilea IV busca fortalecer la estabilidad bancaria global, mejorando la gestión de

presiones externas. Sin embargo, las nuevas regulaciones pueden incrementar la carga administrativa y burocrática, exigiendo más recursos para cumplir con los requisitos de capital, liquidez y apalancamiento, lo que representa una restricción significativa para los bancos (Zuñiga, 2024). Aunque existen múltiples modelos para evaluar el riesgo crediticio y se avanza hacia Basilea IV, aún persisten observaciones no resueltas de Basilea 2.5 y III, planteadas en los *Documentos de Consulta* (CSBB, 2012-2014), entre estos resaltan los límites de carteras, tratamiento del crédito, medición de riesgo y liquidez de mercado, entre otros (Rossignolo, 2019).

El nuevo enfoque introduce dos mejoras principales. Primero, reemplaza el VaR (*Value-at-Risk*) por el ES (*Expected Shortfall*), debido a las limitaciones del VaR como medida de riesgo, tal como señalaron Artzner et al., (2001) citado en Rossignolo, (2019). Segundo, exige una calibración bajo estrés, donde los bancos deben identificar factores de riesgo clave y calcular el ES con un horizonte de 12 meses, la expresión se denota como $ES = ES_{R,S} ES_{F,C} / ES_{R,C}$.

Donde:

ES es el déficit esperado para fines de capital de riesgo.

$ES_{R,S}$ es un conjunto reducido de factores de riesgo en un período de estrés.

$ES_{F,C}$ para un conjunto completo de factores de riesgo en función el período actual (últimos 12 meses).

$ES_{R,C}$ para un conjunto reducido de factores de riesgo en función el período actual (últimos 12 meses).

El Comité de Basilea (BCBS) busca equilibrar el uso de modelos internos (IMA) y estándar (SA) para calcular el capital regulatorio, promoviendo el SA cuando el IMA no sea adecuado. Para reducir discrepancias, exige tres requisitos clave: evaluación global, análisis de actividades comerciales e identificación de factores de riesgo. Si no se cumplen, se aplica el método estándar.

Los bancos deben mantener un capital mínimo diario, siguiendo el enfoque renovado de modelos internos. Según determina la fórmula se tiene que $MCR_i = \max(IMCC_{t-1}; m_c IMCC_{avg})$.

Donde:

$m_c = 1.5(1 + k)$, $IMCC_{t-1}$ son requerimientos mínimos de capital por riesgo de mercado, calculado por el método de modelos internos en el día anterior.

$IMCC_{avg}$ son los requerimientos promedio de los cargos de capital diarios generados por el IMA durante los 60 días anteriores.

m_c es el múltiplo de factor de valor absoluto mínimo de 1.5.

k el factor adicional relacionado con el desempeño ex post del modelo, el cual deben usarse con prudencia.

Tras la aprobación regulatoria, la institución debe superar un *backtesting* bajo Basilea II/III, usando el VaR para ciertos factores (Rossignolo, 2019).

Los modelos de validación estándar como el *backtesting* exigen comparar el VaR estático diario en los percentiles 97.50 % y 99 % en un plazo menor a un año. El $P\&LAT1$ requiere pruebas mensuales con un año de datos recientes frente al P&L real de la cartera. Si se superan 30 (99 %) o 12 (97.5 %) excepciones, la unidad de negociación deberá capitalizarse bajo el método estándar, perdiendo el uso de modelos internos. La expresión se muestra en la Ecuación 16.

Ecuación 15

$$P\&LAT1 = \frac{\frac{1}{n} \sum_{t=1}^n (P\&L_t^T - P\&L_t^A)}{\sigma(P\&L_t^A)}$$

Donde:

el $P\&L_t^T$ es el valor teórico y $P\&L_t^A$ es el valor de día a día.

Si el indicador se sitúa fuera del rango [-10 %, +10 %], la mesa de operaciones experimenta una ruptura y cuatro o más rupturas en el último año significan que la mesa

de operaciones tiene que emplear el método estándar hasta que supere el 20 % y utilizar el $P\&LAT2$ que se muestra en la Ecuación 16.

Ecuación 16

$$P\&LAT2 = \frac{\sigma^2(P\&L_t^T - P\&L_t^A)}{\sigma^2(P\&L_t^A)}$$

En el análisis de factores de riesgo, si el BCBS identifica factores clave, estos deberán integrarse al método estándar revisado. Basilea IV introduce innovaciones para bancos sin modelos sofisticados, usando un 'enfoque de riesgo parcial' con correlaciones predefinidas. Se distingue entre empresas grandes (capitalización \geq USD 2000 millones) y pequeñas. Las que no cumplan estos criterios entrarán en una 'categoría residual' por falta de datos suficientes para su clasificación en los niveles 1-10 (Rossignolo, 2019).

Se aplica la fórmula mostrada en Ecuación 17, que considera cobertura y diversificación por categoría de riesgo (posiciones $1, \dots, n$), donde $RW_i MV_i$ y ρ_{ij} (coeficiente de correlación) son ponderaciones basadas en datos requeridos.

Ecuación 17

$$K_b = \sqrt{\sum_{i=1}^B K_b^2 MV_i^2 + \sum_{i=1}^n \sum_{c>b}^n \rho_{ij} RW_i MV_i RW_j MV_j}$$

Finalmente, se debe realizar el reconocimiento de la cobertura y diversificación entre los distintos segmentos de riesgo. Gracias a ello podrá calcularse el capital de riesgo equitativo (*CRE*), dentro de la suma de los promedios de cada riesgo individual. Esta expresión se muestra en Ecuación 18.

Ecuación 18

$$K_b = \sqrt{\sum_{i=1}^n RW_i^2 MV_i^2 + \sum_{i=1}^B \sum_{j>1}^B \gamma_{bc} S_b S_c + K_{Residual}}$$

Donde:

K_b es el requerimiento de capital determinado.

$K_{Residual}$ es el requerimiento de capital debido al segmento residual.

S_b es la $\sum_{i \in b} RW_i MV_i$ y γ_{bc} es el coeficiente de correlación entre los segmentos b y c, basado de la matriz de correlación.

Discusiones y conclusiones

En concreto, Basilea IV responde a tres aspectos fundamentales:

1. El uso de modelos internos para medir el riesgo de crédito. Se promueve el uso de modelos estándar detallados con el fin de aumentar la transparencia y comparar los niveles de capital entre sus pares. El uso de los modelos internos para aquellos bancos que suelen requerir un menor capital bancario como lo afirmó Zuñiga (2024). El autor también precisa la Revisión Fundamental de la Cartera de Negociación (FRTB), en la que se reemplaza el 'Value at Risk' por el 'Expected Shortfall' como una de las formas más conservadoras para medir el riesgo financiero de una inversión o cartera.
2. Como tercer aspecto se concluye que medir el riesgo operacional cambia y se unifica. En lugar de tener varias maneras de calcular este riesgo, este nuevo enfoque conecta el riesgo operacional directamente con la rentabilidad del banco y se basa en los datos contables. Finalmente, las entidades reguladoras deben realizar un estudio exhaustivo y detallado que refleje con precisión la realidad del sistema financiero, el cual es conocido por su fragilidad e inestabilidad, debido a los constantes shocks externos que lo vuelven más vulnerable e interdependiente.

Este marco regulatorio, aunque más complejo y demandante en cálculos, ofrece

mayor uniformidad en la evaluación de riesgos e incorpora factores de sostenibilidad social y ambiental como criterios indicativos (Thomas, 2022). Surge como respuesta a las deficiencias expuestas por la crisis financiera, en la que los modelos internos mostraron falta de robustez y comparabilidad, especialmente en ciertas clases de activos (Basilea III, 2017). Hoy, ante un escenario global dinámico y con el ascenso de economías emergentes, las criptomonedas y los desplazamientos geopolíticos, Basilea IV busca adaptar el sistema financiero a estas transformaciones, aunque su rigidez podría limitar su efectividad frente a cambios abruptos.

Los países en desarrollo requieren sistemas financieros flexibles y resilientes que promuevan la inclusión financiera y satisfagan demandas crediticias. Implementar métricas objetivas (*rating/scoring*) resulta esencial para evaluar riesgos eficientemente en un entorno global volátil, en el que la liquidez será determinante ante las crisis. Estas herramientas son clave para asegurar estabilidad y acceso al crédito en economías vulnerables. Este estudio aporta a la academia modelos analíticos rigurosos y brinda a las instituciones métodos prácticos para evaluar la solvencia e impago, cerrando la brecha entre teoría y práctica financiera en contextos desafiantes.

Se recomienda que las instituciones financieras colaboren en el desarrollo de modelos innovadores basados en IA, en especial los modelos ML para evaluaciones crediticias más precisas y dinámicas. Paralelamente, es crucial establecer áreas especializadas intercomunicadas que coordinen, monitoreen y establezcan normativas oportunas para los riesgos de impagos y situaciones de default, evitando así impactos en la liquidez corporativa.

La creciente complejidad del sistema financiero exige estandarizar la medición de riesgos bajo Basilea IV, por lo que se requiere mayor difusión, consenso sectorial y formación especializada que garantice una adopción

uniforme de estos estándares regulatorios. Estas medidas combinadas fortalecerán la estabilidad financiera ante un entorno económico cada vez más volátil.

Financiamiento

Esta investigación no recibió una subvención específica de ninguna agencia de financiación en los sectores público, comercial o sin fines de lucro.

Declaración de conflicto de intereses

Los autores declaran no tener potenciales conflictos de interés con respecto a la investigación, autoría y/o publicación de este artículo.

Declaración de aprobación ética o consentimiento informado

Toda la información extraída del estudio se codificará para proteger el nombre de cada sujeto. No se utilizarán nombres u otra información de identificación al discutir o informar datos. Todos los sujetos dieron su consentimiento informado para su inclusión antes de participar en el estudio. Los investigadores mantendrán de forma segura todos los archivos y datos recopilados en un gabinete cerrado con llave en la oficina de los investigadores principales.

Autoría y contribución de los autores

1. **Conceptualización:** Javier Arturo Martínez Farfan, Elizabeth López Meléndez, Luis David Lara Rodríguez
2. **Investigación:** Luis David Lara Rodríguez, Elizabeth López Meléndez, Javier Arturo Martínez Farfan

3. **Metodología:** Elizabeth López Meléndez, Luis David Lara Rodríguez, Javier Arturo Martínez Farfan
4. **Supervisión:** Elizabeth López Meléndez, Javier Arturo Martínez Farfan, Luis David Lara Rodríguez
5. **Redacción del borrador original:** Javier Arturo Martínez Farfan, Elizabeth López Meléndez
6. **Redacción, revisión y edición:** Elizabeth López Meléndez, Javier Arturo Martínez Farfan, Luis David Lara Rodríguez

Referencias

- Álvarez, S., Lochmüller, C., & Osorio, A. (2011). La medición del riesgo crédito en Colombia y el Acuerdo de Basilea III. *Revista Soluciones de Postgrado*, 4(7), 49–66.
- Alomoto, T. (2017). *Metodología de cuantificación del riesgo operativo para las cooperativas de ahorro y crédito del segmento 4, aplicando Simulación Montecarlo*. Obtenido de <http://hdl.handle.net/10644/5706>
- Al-Shabi, M. A. (2019). Credit Card Fraud Detection Using Autoencoder Model in Unbalanced Datasets. *Journal of Advances in Mathematics and Computer Science*, 33(5), 1-16. doi: <https://doi.org/10.9734/jamcs/2019/v33i530192>
- Altman, E. (1968). FINANCIAL RATIOS, DISCRIMINANT ANALYSIS AND THE PREDICTION OF CORPORATE BANKRUPTCY. *The Journal of Finance*, XXIII(4). doi:Altman, E. (1968). Financial ratios, discriminant analysis and the prediction of
- Amat, J. (Abril de 2018). *Tobit Regression: modelos lineales para datos censurados*. Obtenido de https://cienciadedatos.net/documentos/40_tobit_regression_modelos_lineales_para_datos_censurados
- Arévalo, R., Aguilar, E., & Mejía, S. (2018). *Estimación del riesgo de crédito para portafolios de reservas internacionales*. Retrieved from Banco Central de Reserva del Perú: <https://www.secmca.org/recard/index.php/foro/article/view/17/11>

- Artzner, P., Delbaen, F., Eber, J., & Heath, D. (2001). Coherent Measures of Risk. *Mathematical Finance*, 9(9), 203-228. doi: <https://doi.org/10.1111/1467-9965.00068>
- Balanta, S. (2024). RAMPA DE ILIQUIDEZ: LOS SUJETOS SOBREENDEUDADOS Y SUS CONSECUENCIAS COGNITIVA. *Revista de Administración de Empresas*, 64(1). doi: <https://doi.org/10.1590/S0034-759020240103>
- Banco de Pagos Internacionales, B. (2015). Comité de Supervisión Bancaria de Basilea. *Revisión del Método Estándar para el riesgo del crédito*. Suiza: Banco de Pagos Internacionales 2014. doi: ISBN 978-92-9197-026-1
- Basilea III, C. d. (2017). Resumen de las reformas de Basilea III. Banco de Pagos Internacionales 2017. doi: ISBN 978-92-9259-121-2
- Belalcazar, R., & Trujillo, A. (2016). ¿Es el modelo Z-Score de Altman un buen predictor de la situación financiera de las Pymes en Colombia? Santiago de Cali-Colombia.
- Benavente, J., & Porter, N. (2014). Calificaciones crediticias. *Serie Para Consumidores|Finanzas-Hoja informativa número 9.142*.
- Bermúdez, I., Manotas, D., & Olaya, J. (2020). Modelo para la estimación del deterioro por riesgo de crédito. *Suma de Negocios*, 149-157.
- Bonilla, M., Olmeda, I., & Puertas, R. (2003). Modelos Paramétricos y no Paramétricos en Problemas de Credit Scoring. *REVISTA ESPAÑOLA DE FINANCIACIÓN Y CONTABILIDAD*, XXXIII(118), 833-869.
- Borrero, D., & Bedoya, O. (2020). Predicción de riesgo crediticio en Colombia usando técnicas de inteligencia artificial. *Revista UIS Ingenierías*, 19(4). doi:<https://doi.org/10.18273/revuin.v19n4-2020004>
- Butaru, F., Chen, Q., Clark, B., Das, S., & Siddique, A. (2016). Risk and risk management in the credit card industry. *Journal of Banking & Finance*, 72, 218-239. doi:<https://doi.org/10.1016/j.jbankfin.2016.07.015>
- Cindik, Z., & Armutlulu, I. (2021). A revision of Altman Z-Score model and a comparative analysis of Turkish companies' financial distress prediction. *National Accounting Review*, III(2), 237-255. doi: <https://doi.org/10.3934/NAR.2021012>
- Caballero, L., López, A., & Bautista, J. (2015). Arbol de decisión C4.5 basado en entropía. *Research in Computing Science*, 92, 23-34.
- Cabrera, W., Segovia, S., & Mariño, J. (2019). Probabilidad de incumplimiento de entidades financieras colombianas: una aproximación estructural. *EconPapers: Borradores de Economía*(197). doi: <https://doi.org/10.32468/be.1097>
- Caicedo, E., Claramunt, M., & Casanovas, M. (2011). Medición del riesgo de crédito mediante modelos estructurales: una aplicación al mercado colombiano. *Cuadernos de Administración*, 24(42). doi: ISSN 0120-3592
- Calificadora de Riesgo Moody's, M. (04 de Agosto de 2023). EE.UU. propone reglas finales de Basilea y período de transición que comenzará en julio de 2025. Obtenido de <https://www.moody.com/web/en/us/insights/regulatory-news/us-proposes-final-basel-rules-transition-period-to-start-in-july-2025.html>
- Candian, M. (11 de Setiembre de 2024). *Score Crediticio: ¿qué es, importancia y cómo analizarlo?* Obtenido de <https://www.sydle.com/es/blog/score-crediticio-66688f2a-23f910085db97011>
- Cardona, P. (2004). Aplicación de árboles de decisión en modelos de riesgo crediticio. *Revista Colombiana de Estadística*, 27(2), 139 - 151. doi:ISSN: 0120-1751
- Carruthers, D. (09 de Enero de 2023). *Credit Correlations: Avoiding Unnecessary Risks*. Obtenido de <https://www.creditbenchmark.com/credit-correlations-avoiding-unnecessary-risks/>
- Caruana, J., & Narain, A. (2008, Junio). *Una banca más*. Retrieved from <https://www.imf.org/external/pubs/ft/fandd/spa/2008/06/pdf/caruana.pdf>
- Chatterjee, S. (2016). Modelos de Riesgos de Crédito. *Centre for Central Banking Studies, Banco de Inglaterra*, 5-28.
- Chaudhuri, K., & Cheral, M. (2012). Credit rationing in rural credit markets of India. *Applied Economics*, XLIV(7), 803-812. doi: <https://doi.org/10.1080/00036846.2010.524627>
- Chi, G., Uddin, M., Ying, T., Rashidul, Z., & Iqbal, M. (2020). A hybrid model for credit risk assessment: empirical validation by real-world

- credit data. *Journal of Risk Model Validation*, XIV(4), 1-39. doi: <https://doi.org/10.21314/JRMV.2020.228>
- Chorafas, D. (2000). *Managing Credit Risk: Analyzing, rating and pricing the probability of default*. Euromoney Books. doi: <https://doi.org/1855647613>
- Dassatti, C. (2019). Modelos de Score Crediticio: revisión metodológica y análisis a partir de datos de encuesta. *Banco Central del Uruguay*, 1-33.
- Delgado, M. (2022). ¿Tener una buena calificación crediticia sin haber pedido antes un préstamo? *THEMIS Revista de Derecho*, 33-41.
- Demirag, I., & Goddard, S. (1999). *Financial management for international business*. Library of Congress Cataloguing in Publication Data. doi: <https://doi.org/10-415-18161-5>
- Echegaray, V. (2022). Riesgo de Crédito: Evidencia en la banca múltiple peruana. *Bolentín de Coyuntura*, 32, 6-16. doi: e-ISSN 2600 - 5727
- Editores de CQF, C. i. (2025). *What are Credit Derivatives?* Obtenido de <https://www.cqf.com/blog/what-are-credit-derivatives>
- Editores de Mint2Save, M. (29 de Setiembre de 2023). *Mint2Save*. Obtenido de Understanding the Moody's KMV Model: Measuring Credit Risk: <https://www.mint2save.com/understanding-the-moodys-kmv-model-measuring-credit-risk/>
- Feridun, M., & Özün, A. (2020). Basel IV implementation: a review of the case of the European Union. *Journal of Capital Markets Studies*, 4(1), 7-24. doi: <https://doi.org/10.1108/JCMS-04-2020-0006>
- Fica, A., Aranguiz, M., & Gallegos, J. (2018). Análisis de riesgo crediticio, propuesta del modelo credit scoring. *Análisis de riesgo crediticio, propuesta del modelo credit scoring*, 26(1), 181-207. doi: <https://doi.org/10.18359/rfce.2666>
- Flores, M. (2012). Metodología utilizada para el cálculo de riesgo crédito en un portafolio eficiente de crédito al consumo. *Tiempo Económico*, 20(VII).
- García, M. (2022). *Riesgo de concentración crediticia sectorial: determinación de una configuración óptima de exposiciones sectoriales de una cartera de créditos, en el marco de Basilea III*. Obtenido de <https://repositorio.uchile.cl/handle/2250/187202?show=full>
- Ghidalia, S., Narsis, O. L., Bertaux, A., & Nicolle, C. (2024). Combining Machine Learning and Ontology: A Systematic Literature Review. *arXiv*, 1-38. doi: <https://doi.org/10.48550/arXiv.2401.07744>
- Ghosh, A. (2015). Banking-Industry Specific and Regional Economic Determinants of Non-Performing Loans: Evidence from US States. *Journal of Financial Stability*, 20, 93-104. doi: <https://doi.org/10.1016/j.jfs.2015.08.004>
- Guerra, D., & León, I. (2018). Principales tendencias teóricas y modelos generales de la evaluación del riesgo de crédito bancario. *REDEL. Revista Granmense de Desarrollo Local*, 259-270.
- Gómez, L., & Checo. (2014). La Gestión del Riesgo de Crédito como herramienta para una Administración Financiera eficiente. Un estudio de caso. *Revista del cono Sur de las Américas*, 24-32.
- Gonzales, J. (15 de Agosto de 2016). *La caída del petróleo desde junio de 2014 es la mayor de los últimos 40 años*. Recuperado el 16 de Noviembre de 2024, de https://www.abc.es/economia/abci-caida-petroleo-desde-junio-2014-mayor-ultimos-40-anos-201608151822_noticia.html?ref=https%3A%2F%2Fwww.abc.es%2Feconomia%2Fabci-caida-petroleo-desde-junio-2014-mayor-ultimos-40-anos-201608151822_noticia.html
- Hait, S. (2023). *BASEL IV*. Obtenido de <https://www.exlservice.com/insights/white-paper/basel-iv>
- Hayashi, Y. (2022). Emerging Trends in Deep Learning for Credit Scoring: A Review. *Electronics*, 11(19), 1-30. doi: <https://doi.org/10.3390/electronics11193181>
- Hermitaño, J. (2022). Aplicación de machine learning en la gestión de riesgo de crédito financiero: Una revisión sistemática. *INTERFASES, XII*, 160-178. doi: <https://orcid.org/0000-0001-6580-880X>
- Holton, G. (2013). *Valor en Riesgo: teoría y Práctica*. Obtenido de <https://www.value-at-risk.net/motivation-historical-simulation/>

- Isotools. (2023). *Cómo implementar la ISO 31000 en tu empresa*. Obtenido de <https://www.isotools.us/2023/12/21/como-implementar-la-iso-31000-en-tu-empresa/>
- Jadresic, E., & Schmidt-Hebbel, K. (2003). CRISIS FINANCIERAS INTERNACIONALES, PRESTAMISTA DE ULTIMA INSTANCIA Y NUEVA ARQUITECTURA FINANCIERA INTERNACIONAL. *Cuadernos de economía*, 359-391.
- Kenworthy, P., Kose, A., & Perevalov, N. (2024, Febrero 08). *Una crisis de deuda silenciosa hunde a las economías en desarrollo con bajos índices de solvencia crediticia*. Retrieved Noviembre 16, 2024, from <https://blogs.worldbank.org/es/voices/crisis-de-deuda-silenciosa-hunde-economias-en-desarrollo-bajos-indices-solvencia-crediticia>
- Knop, R., Ordovàs, R., & Vidal, J. (2013). *Medición de Riesgos de Mercado y Crédito*. Madrid: Delta, Publicaciones Universitarias.
- Kukuk, M., & Rönnerberg, M. (2013). Corporate credit default models: a mixed logit approach. *Review of Quantitative Finance and Accounting*, 41(3), 467-483. doi: <https://doi.org/10.1007/s11156-012-0281-4>
- Labanda, A. (2005). DERIVADOS DE RIESGO DE CRÉDITO. TIPOS Y UTILIDADES. *Documento de Trabajo: Universidad Complutense y Universidad Autónoma*(0506).
- Le Quy Tai, & Giang Thi Thu Huyen. (2019). Deep Learning Techniques for Credit Scoring. *Journal of Economics, Business and Management*, 7(3), 1-4. doi: <https://doi.org/10.18178/joebm.2019.7.3.588>
- Leijnen, S., & Veen, F. (2020). The neural network zoo. *Proceedings*, 47(1), 1-6. doi: <https://doi.org/10.3390/proceedings2020047009>
- Leung, K., Cheong, F., Cheong, C., O'Farrell, S., & Tis-sington, R. (2008). Proceedings of the 7th International Conference on Computational Intelligence in Economics and Finance. *The 7th International Conference on Computational Intelligence in Economics and Finance* (pp. 1-7). Taiwán: Kainan University; Taiwan.
- López, A., Chumacero, J., & Arrojo, A. (Directors). (2024). *Metodologías del VaR de Crédito* [Motion Picture].
- Márquez, J. (2006). *UNA NUEVA VISIÓN DEL RIESGO DE CRÉDITO*. LIMUSA. doi:9789681868321
- Marín, J. (2007). *Análisis Multivariante*. Obtenido de https://ocw.uc3m.es/pluginfile.php/602/mod_page/content/17/12_Metodos_graficos_para_datos_multivariantes.pdf
- Martínez, C., & del Río, A. (2004). Las implicaciones del endeudamiento de los hogares sobre el consumo privado. *Boletín Económico/Banco de España*, 49-54.
- Martínez, D., Bucio, C., & Ortiz, E. (2021, Enero 20). Cópulas dinámicas en el índice de morosidad del crédito al consumo en México. *Revistas de la Universidad de Manizales*, 1(22). doi: <https://doi.org/10.30554/lumina.v22.n1.4132.2021>
- Mashrur, A., Luo, W., Zaidi, N., & Robles, A. (2020). Machine Learning for Financial Risk Management: A Survey. *IEEE Access*, 8, 203203-203223. doi: <https://doi.org/10.1109/ACCESS.2020.3036322>
- Morales, J., & Tuesta, P. (1998). Calificaciones de crédito y riesgo país. *Revista Estudios Económicos*(3).
- Nica, I., Delcea, C., & Chirita, N. (2024). Mathematical Patterns in Fuzzy Logic and Artificial Intelligence for Financial Analysis: A Bibliometric Study. *Mathematics*, 12(5), 782. doi: <https://doi.org/10.3390/math12050782>
- Novales, A. (2017). Riesgo de crédito. In J. Hull, *Risk Management and Financial Institutions*.
- Oketunji, A. F., Anas, M., & Saina, D. (2023). Large Language Model (LLM) Bias Index -- LLM-BI. *Computation and Language*, 1-14. doi: <https://doi.org/10.48550/arXiv.2312.14769>
- Paramesha, M., Rane, N. L., & Rane, J. (2024). Artificial Intelligence, Machine Learning, Deep Learning, and Blockchain in Financial and Banking Services: A Comprehensive Review. *Partners Universal Multidisciplinary Research Journal*, 1(2), 51-67. doi: <https://doi.org/10.5281/zenodo.12826933>
- Pérez, F., & Fernández, H. (2007). Las redes neuronales y la evaluación del riesgo de crédito. *Revista Ingenierías Universidad de Medellín*, VI(10), 77-91. doi:ISSN: 1692-3324
- Rayo, S. (2024). *Gestión Avanzada de Riesgos de Crédito: Seminario para gerentes de riesgos de las entidades de microfinanzas*. Lima: Superintendencia de Banca y Seguros - Banco Interamericano de Desarrollo.

- Reinhart, C., & Rogoff, K. (2010). DEL CRASH FINANCIERO A LA CRISIS DE LA DEUDA. *National Bureau of Economic Research, Inc, NBER Working Papers*, 101. doi: <https://doi.org/10.1257/aer.101.5.1676>
- Rey, R., & Ross, L. (1993). Finance and Growth: Schumpeter Might Be Right. *Quarterly Journal of Economics*, 108(3), 17-37. doi: <https://doi.org/10.2307/2118406>
- Reyes, P. (2025). ¿Qué es un rating? Recuperado el 14 de Septiembre de 2024, de <https://www.bbva.com/es/economia-y-finanzas/que-es-un-rating/>
- Rodríguez, David, Becerra, J., & Cardona, D. (2017). MODELOS Y METODOLOGÍAS DE CREDIT SCORE PARA PERSONAS NATURALES: UNA REVISIÓN. *Revista CEA*, III(5), 13-28. doi: ISSN -e 2422-3182
- Roque, D., & Caicedo, A. (2022). Detección de insolvencia financiera mediante el modelo Z-Altman en empresas colombianas no cotizantes durante el periodo 2016-2019. *Administración y Contabilidad*, XVII(33), 167-192. doi: <https://doi.org/10.18800/contabilidad.202201.007>
- Rossignolo, A. (2019). Basel IV A gloomy future for Expected Shortfall risk models. *Revista Mexicana de Economía y Finanzas Nueva Época*, 14, 559-582. doi: <https://doi.org/10.21919/remef.v14i0.423>
- Ruza, C., & Curbera, P. (2013). *El Riesgo de crédito en perspectiva* (Primera ed.). Madrid: Universidad Nacional a Distancia.
- Saavedra, M., & Saavedra, M. (2010). Modelos para Medir el riesgo de crédito de la banca. *Cuadernos de Administración*, 295-319.
- Samaniego, R. (2008). *El Riesgo de Crédito: en el marco de Acuerdo de Basilea II*. Delta Publicaciones Universitarias.
- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 160.
- Seijas, M., Vivel, M., Lado, R., & Fernández, S. (2017). LA EVALUACIÓN DEL RIESGO DE CRÉDITO EN LAS INSTITUCIONES DE MICROFINANZAS: ESTADO DEL ARTE. *COMPENDIUM*, IV(9), 36-52. doi:ISSN Online 1390-9894
- Servigny, A., & Olivier, R. (2004). *Measuring and Managing Credit Risk*. McGraw Hill Professional. doi:9780071788007
- Sotomayor, S. (2012). *Estimación de la pérdida esperada para una cartera de microcrédito basada en calificaciones internas*. Obtenido de <https://bibdigital.epn.edu.ec/bitstream/15000/4668/1/CD-4301.pdf>
- Tam, A. (24 de Enero de 2019). *Gaussian copula and multivariate normal distribution*. Obtenido de <https://www.adrian.idv.hk/2019-01-24-copula/>
- Tavera, S. (2014). *GESTION DE RIESGOS DE CRÉDITO PARA EMPRESAS DEL SECTOR NO FINANCIERO*. UNIVERSIDAD MILITAR NUEVA GRANADA FACULTAD DE CIENCIAS ECONÓMICAS, BOGOTÁ.
- Téllez, M. (Junio de 2010). *Medición del riesgo en crédito: Implementación y cálculo del VaR y el CVaR en tres modelos de incumplimiento*. Obtenido de <https://doi.org/10.24275/uami.2j62s4987>
- Thomas, M. (03 de Julio de 2022). "Basilea IV": cómo serán las nuevas regulaciones de la actividad bancaria en el mundo. Obtenido de Diario La Nación: <https://www.lanacion.com.ar/economia/basilea-iv-como-seran-las-nuevas-regulaciones-de-la-actividad-bancaria-en-el-mundo-nid03072022/>
- Toledo, E., & León, V. (2021). Matriz de transición: una herramienta para determinar la probabilidad de default en las instituciones microfinancieras. *Apuntes Contables*, 29, 99-121. doi: <https://doi.org/10.18601/16577175.n29.07>
- Urbina, M. (2019). Riesgo de crédito: Evidencia en el sistema bancario ecuatoriano. *Universidad de las Fuerzas Armadas - ESPE - Ecuador*(23), 4-9. doi: <http://dx.doi.org/10.31164/bcoyu.23.2019.842>
- Vargas, A., & Mostajo, S. (2014). Medición del riesgo crediticio mediante la aplicación de métodos basados en calificaciones internas. *Investigación & Desarrollo*, 5-25.
- Vasicek's, O. (2015). Loan Portfolio Value. *Finance, Economics, Mathematics*, 149-160. doi: <https://doi.org/10.1002/9781119186229.ch19>

- Velásquez, F. (2023). Elementos explicativos de endeudamiento de las empresas. *Análisis Económico*, XIX(40), 215-244.
- Wolpert, D. H., & Macready, W. G. (1997). No free lunch theorems for optimization. *IEEE Transactions on Evolutionary Computation*, 1(1), 67-82. doi: <https://doi.org/10.1109/4235.585893>
- Xu, Q., Feng, Z., Gong, C., Wu, X., Zhao, H., Ye, Z.,... Wei, C. (2024). Applications of Explainable AI in Natural Language Processing. *Global Academic Frontiers*, 2(3), 51-64. doi: <https://doi.org/10.5281/zenodo.12684705>
- Zahidur, R. F. (2024). Evaluating the impact of AI and blockchain on credit risk mitigation: A predictive analytic approach using machine learning. *International Journal of Science and Research Archive*, 13(1), 575-582. doi:<https://doi.org/10.30574/ij-sra.2024.13.1.1707>
- Zapata, C. (2021). Estimación del riesgo de crédito en proyectos de infraestructura mediante modelos estructurales. *Contaduría y Administración*, 66(1), 1-24. doi:<http://dx.doi.org/10.22201/fca.24488410e.2020.2510>
- Zapata, R. (2024). *Modelos predictivos para la gestión de riesgo de crédito: aplicación de Random Forest y árboles de decisión*. Obtenido de <http://dspace.udla.edu.ec/handle/33000/16218>
- Zuñiga, M. (10 de Julio de 2024). *Basilea IV: Las nuevas directrices para una banca global resiliente*. Obtenido de <https://garcianadal.cl/basilea-iv-las-nuevas-directrices-para-una-banca-global-resiliente/>



Copyright © The Author(s) - 2026