

## INTELIGENCIA ARTIFICIAL EN CIENCIA DE DATOS APLICADA A LA GESTIÓN DE RIESGOS FINANCIEROS EN ENTIDADES BANCARIAS

LSi. Fernando Leòn Gavilànez, MSc , [fleon@uagraria.edu.ec](mailto:fleon@uagraria.edu.ec)

MSc Jonatan Israel León Gavilánez PHD (c) [jleon@alvarezvalvarezec.com.ec](mailto:jleon@alvarezvalvarezec.com.ec)

Ing. Ronald Barriga Diaz, Phd,MSc. , [ronald.barrigad@ug.edu.ec](mailto:ronald.barrigad@ug.edu.ec)

Ing. Myriam Garcia E.,MSc. , [myriam.garciae@ug.edu.ec](mailto:myriam.garciae@ug.edu.ec)

### Palabras Clave

instituciones financieras,  
prestatarios, riesgo  
crediticio, riesgos  
financieros, solvencia.

### Historia del

#### Artículo Recibido

Recibido 01-04-2024

Revisado 1-11-2024

Aceptado 01-12-2024

Publicado 20-12-2024

### Resumen

La aplicación de la Ciencia de Datos en el ámbito de los riesgos financieros bancarios ha ganado cada vez más importancia en los últimos años. La implementación de la Inteligencia Artificial (IA) en la Ciencia de Datos mediante herramientas y técnicas puede ayudar a diversas instituciones financieras a identificar, medir, controlar y mitigar de manera más efectiva los riesgos asociados a sus operaciones diarias.

En este trabajo se revisan diversas herramientas para la gestión de riesgos financieros, aprovechando la capacidad de la Ciencia de Datos para analizar grandes volúmenes de datos y evaluar la solvencia crediticia de los prestatarios. Esto resulta especialmente valioso en la identificación de factores que los métodos tradicionales podrían pasar por alto, lo que, a su vez, habilita una toma de decisiones más precisa en la concesión de préstamos. Además, se explora el desarrollo de modelos de riesgos financieros más sofisticados, capaces de capturar relaciones más complejas entre variables y proporcionar estimaciones más precisas de los niveles de riesgo.

Sin embargo, es importante tener en cuenta que la implementación exitosa de la Inteligencia Artificial en la Ciencia de Datos para la gestión de riesgos financieros también conlleva desafíos. Estos incluyen datos de alta calidad, la interpretación de los resultados generados por algoritmos complejos, la consideración de aspectos éticos y de privacidad, y la capacitación de personal para comprender y utilizar eficazmente las herramientas de Ciencia de Datos.

**Keywords**

financial institutions,  
borrowers, credit risk,  
financial risks, solvency.

**Article History**

Received 01-04-2024

Revised 1-11-2024

Accepted 01-12-2024

Published 20-12-2024

**Abstract**

The application of Data Science in the field of banking financial risks has gained increasing importance in recent years. The implementation of Artificial Intelligence (AI) in Data Science through tools and techniques can help various financial institutions to more effectively identify, measure, control, and mitigate the risks associated with their daily operations.

This work reviews various tools for financial risk management, leveraging the capability of Data Science to analyze large volumes of data and evaluate the creditworthiness of borrowers. This is particularly valuable in identifying factors that traditional methods may overlook, thereby enabling more precise decision-making in lending. Furthermore, it explores the development of more sophisticated financial risk models capable of capturing more complex relationships between variables and providing more accurate risk level estimates.

However, it's important to consider that the successful implementation of Artificial Intelligence in Data Science for financial risk management also comes with challenges. These include high-quality data, the interpretation of results generated by complex algorithms, the consideration of ethical and privacy aspects, and the training of personnel to understand and effectively use Data Science tools.

## INTRODUCCIÓN

La aplicación de la Ciencia de Datos en la gestión de riesgos financieros es una de las áreas más destacadas en la industria bancaria. La Ciencia de Datos ofrece herramientas y técnicas que permiten a las instituciones financieras evaluar de manera más precisa y eficiente la solvencia crediticia de los prestatarios (Prado, 2021); sin embargo, hay varias problemáticas y desafíos que las instituciones financieras enfrentan en este ámbito. Algunos de estos desafíos incluyen, por ejemplo, la liquidez, el análisis de tasa de interés del mercado de un producto o servicio, o que la información del prestatario es incompleta o inconsistente, lo que dificulta una evaluación precisa de su capacidad crediticia, las condiciones económicas y del mercado pueden cambiar rápidamente, lo que afecta la capacidad de los prestatarios para cumplir con sus obligaciones crediticias (Wong, 2021).

Los modelos de riesgo deben ser capaces de adaptarse a las problemáticas y desafíos del proceso de evaluación de las instituciones financieras. Los modelos tradicionales de *scoring* crediticio pueden no ser capaces de capturar las complejidades de la solvencia crediticia de los prestatarios, especialmente en situaciones donde las relaciones no lineales y los factores externos juegan un papel crucial, y por ende, las instituciones financieras deben cumplir con regulaciones y normativas estrictas en relación con la concesión de crédito, lo que agrega una capa adicional de complejidad a la gestión de riesgos de crédito. Abordar estas problemáticas requiere enfoques innovadores, como el uso de la Ciencia de Datos, el análisis de *big data* y el desarrollo de modelos más sofisticados con Inteligencia Artificial (IA) que consideren una amplia gama de factores para evaluar de manera más precisa el riesgo crediticio, de mercado y liquidez (Koulafetis, 2017).

La Ciencia de Datos se puede crear modelos de *scoring* más complejos y precisos al considerar una amplia gama de variables y patrones. Es así que, la Ciencia de Datos puede analizar grandes volúmenes de datos, incluyendo datos estructurados (información financiera, historial de pagos, etc.) y no estructurados (redes sociales, comportamiento en línea, etc.), para evaluar la capacidad

crediticia de un prestatario, la reacción del mercado macroeconómico, la capacidad de liquidez en un rango de meses, esto permite una visión más completa y precisa de la situación financiera del individuo o empresa. Por otra parte, la IA puede monitorear el comportamiento crediticio de los clientes en tiempo real y detectar patrones inusuales. Con Los algoritmos de aprendizaje automático pueden identificar relaciones no lineales y sutilezas en los datos que los modelos tradicionales podrían pasar por alto. Esto es especialmente útil para identificar cambios en la solvencia de un prestatario y tomar medidas preventivas si se observan signos de deterioro financiero; incluso puede ayudar a segmentar a los clientes en diferentes categorías de riesgo según sus características y comportamientos financieros.

Mientras los modelos de *scoring* tradicionales se basan en reglas fijas y relaciones lineales, los modelos más sofisticados permiten una asignación de recursos más eficiente y la aplicación de estrategias de gestión de riesgos personalizadas para anticipar problemas de pago y reducir las pérdidas por incumplimiento. Ahora bien, es indispensable mantener un equilibrio entre la automatización y la intervención humana para tomar decisiones, independientemente de la aplicación de los modelos tradicionales o complejos.

En este artículo se analiza el ciclo de gestión de riesgos financieros en sus fases de identificación, medición, control y monitoreo (Tony Van Gestel, 2019), mediante una investigación cualitativa de revisión documental de libros, artículos, informes y registros históricos, para sugerir herramientas de Ciencia de Datos que optimicen las fases del ciclo de gestión de riesgos financieros y su viabilidad en la implementación de estas fases en una entidad financiera.

## RESULTADOS Y DISCUSIÓN

La gestión de riesgos financieros es una de las áreas en las que la Ciencia de Datos puede brindar un valor significativo, ya que ayuda a las instituciones financieras a identificar patrones, tendencias y señales de advertencia que podrían indicar la probabilidad de incumplimiento de un prestatario, iliquidez, riesgos de tasa de interés, entre otros. En esta sección se analiza el ciclo de gestión de riesgos financieros en sus fases de identificación, medición, control y monitoreo.

### Identificación de Riesgos Financieros

El proceso de identificación es el reconocimiento de todos los factores que al presentar comportamientos adversos, originan un incremento en el riesgo, lo que significa, identificar tanto el riesgo potencial en la concesión de créditos nuevos, inversiones en el mercado primario, como el posible deterioro de la calidad crediticia de operaciones ya desembolsadas (Allen A. S., 2021). La identificación de riesgos inherentes de una entidad utilizando inteligencia artificial (IA) implica aprovechar las capacidades de la Ciencia de Datos para analizar grandes cantidades de datos y descubrir patrones, tendencias y relaciones que podrían no ser evidentes a simple vista. Aunque la implementación de metodologías y estudios se encuentra en constante evolución y aplicación, se ha considerado cuatro actividades y criterios claves para definir el proceso de identificación del riesgo de crédito que adoptará la entidad.

### Identificación de Riesgos Inherentes

El riesgo inherente es aquel que puede existir de manera intrínseca en toda actividad. Puede generarse por factores internos o externos y afectar la rentabilidad y el capital de las empresas. No puede ser eliminado, por lo cual dado su identificación es contemplado en los planes de gestión de presupuestos y planes de negocio de la entidad. Los riesgos inherentes se clasifican en los siguientes:

- Factores externos
  - Políticas y normas
-

- Estrategia interna de la entidad
- Rentabilidad Objetivo de la gestión financiera
- Control interno

Todos los riesgos inherentes no son negativos, por ello la entidad gestiona con el área de planeación la posible transformación de esta identificación de riesgos en oportunidades que se convierten en productos y servicios que entreguen resultados positivos. Cuando se asumen los riesgos inherentes, la unidad de riesgos entrega a la alta gerencia un análisis de probabilidad de ocurrencia con el objetivo de reducir su nivel de impacto y lograr los objetivos de manera óptima. De esta forma, se transforma el riesgo inherente en residual.

#### Identificación de Riesgo Sectorial

El análisis sectorial es esencial para conocer las posibilidades de crecimiento de un negocio en un mercado determinado. El análisis sectorial es la herramienta perfecta para diseñar estrategias de mercado orientadas a segmentos específicos para la entidad. Para ello, es necesario tener en cuenta la competencia que se presenta a dos niveles básicos: los productos y servicios (la venta en sí misma) y la de los factores (comportamiento del mercado para productos similares). Por ello, el riesgo sectorial que analiza el banco se define como la vulnerabilidad existente ante un posible perjuicio a producirse en función a la presencia de factores (muchos de ellos no controlables) que afectan una condición determinada

#### Identificación del Nivel de Exposición de Morosidad.

El nivel de exposición (NE) es una medida de la frecuencia con la que se da exposición al riesgo financiero. Para el riesgo de crédito, el nivel de exposición se puede estimar en función de las siguientes variables:

- Identificación de concentración por segmento de crédito.
- Identificación de concentración por sujeto de crédito y persona jurídica.

- Identificación del nivel de exposición de morosidad.
- Identificación de la Morosidad de operaciones otorgadas menores a 90 días.

Para establecer las variables, se procede a identificar la naturaleza de las mismas, la razonabilidad y el valor del indicador.

#### Identificación de Perfiles de Riesgos por Segmentos de Crédito

El perfilamiento de riesgo de crédito es un tema relevante para las entidades financieras, toda vez que identifica los factores generadores de riesgo de crédito (edad, género, capacidad de pago), además de contribuir en la implementación de Sistemas de Gestión de Riesgos para la originación y el seguimiento de la cartera colocada en diversos segmentos de mercado.

En ese sentido, este proceso busca identificar el perfil de riesgos por segmento de cartera de crédito (buenos y malos) de la entidad, para lo cual se utiliza una metodología denominada ACP Análisis de Componentes Principales con clústeres jerárquicos, que luego de ser aplicado da como resultado que diversos tipos de clientes presentan como factores generadores de riesgo, el género, un rango de edad, ingresos promedio, estado civil, poca antigüedad como clientes en el Sistema Financiero Bancario, encontrarse empleado en empresas de cierta naturaleza, tener operaciones con montos altos, es decir diversas variables sociodemográficas y de comportamiento financiero.

#### Medición de Riesgos Financieros

La medición de riesgos financieros es un proceso fundamental en la gestión financiera y crediticia de una institución o entidad financiera. Se refiere a la evaluación de portafolios de inversión con base en variables macroeconómicas o de comportamiento del papel en un mercado determinado, o en la probabilidad de que un prestatario incumpla en el pago de sus obligaciones crediticias (Rennie, 2017), es decir, no reembolse el préstamo o crédito según los términos acordados. Esta medición ayuda a las instituciones financieras a tomar decisiones informadas sobre la concesión

de créditos, la inversión en diversos portafolios locales o del extranjero y a establecer las condiciones apropiadas para mitigar los riesgos involucrados.

La medición de riesgos financieros implica aprovechar la capacidad de la Ciencia de Datos para analizar grandes volúmenes de datos y generar modelos más precisos y adaptativos para evaluar y predecir el riesgo de incumplimiento de los prestatarios.

### **Modelo de Originación de Scoring para Colocación de Recursos**

Las instituciones financieras pueden desarrollar modelos matemáticos o estadísticos (modelos de *scoring*) que consideran múltiples variables para estimar la probabilidad de incumplimiento. Estos modelos pueden incluir factores como ingresos, historial crediticio, edad, empleo y más. De acuerdo con esto, la metodología a utilizar es de análisis discriminante, donde el total de la información se divide en dos grupos para ser comparados, por ejemplo, los grupos son las operaciones que se encuentran en default y los que no, este tipo de análisis ayuda a diferenciar las características que contienen cada grupo de operaciones; lo cual permite pronosticar de acuerdo con sus características si estará o no en default. El objetivo de este modelo es asignar puntajes a cada perfil de cliente de la institución financiera, para determinar, dadas las características cuantitativas y cualitativas, si el cliente tendrá una alta o baja probabilidad de caer en default, y de esta manera agilizar el trámite de un crédito y hacerlo menos subjetivo. Este tipo de procedimientos se denomina minería de datos o *DataMining*, pues permite extraer información relevante y encontrar patrones de comportamiento de los datos; para posteriormente utilizar esta información relevante, en un análisis descriptivo y predictivo de los datos (Bart Baesens, 2017).

### **Modelo de Pérdida Esperada**

Las agencias de calificación crediticia asignan puntuaciones crediticias basadas en la información financiera y crediticia de los prestatarios. Estas puntuaciones reflejan la probabilidad estadística de incumplimiento y son utilizadas por las instituciones financieras para evaluar el riesgo

crediticio y estimar su probable pérdida esperada (Colquitt, 2018). Se considera la pérdida esperada como una función los siguientes parámetros:

- Probabilidad de incumplimiento o default (PD).
- Exposición al momento de incumplimiento (EAD).
- Pérdida dado el default (LGD).

Una vez obtenida la probabilidad de incumplimiento y la tasa de recuperación, se calculará la pérdida esperada en base a la fórmula

$$PE = EAD * PD * (1 - r)$$

Dónde:

EAD = Nivel de exposición del riesgo de crédito, dado por el valor presente (al momento de producirse el incumplimiento) de los flujos que se espera recibir de las operaciones crediticias;

PD = Probabilidad de incumplimiento

r = tasa de recuperación; dada por el porcentaje de la recaudación realizadas sobre las operaciones de crédito que han sido incumplidas.

La pérdida esperada constituye el valor esperado (promedio) de la pérdida, en función de la probabilidad de incumplimiento, el nivel de exposición (en valor presente) en el momento de incumplimiento, y la severidad de la pérdida, expresa como  $1 - r$ .

Se puede interpretar a la pérdida esperada como una pérdida media o promedio basada en los parámetros de frecuencia y severidad, aplicados al valor presente del monto que ha caído en incumplimiento.

### Control De Riesgos Financieros

Según los principios de supervisión de Basilea, se establece que los bancos deberían definir un sistema de revisión independiente y continuo de créditos y los resultados de las revisiones deberían ser reportados directamente al directorio y la alta gerencia, adicional a ello, los bancos

tienen que garantizar que la función de otorgar créditos se administra adecuadamente y que las exposiciones del riesgo a analizar se encuentran dentro de los niveles que son coherentes con normas prudenciales y límites internos (John B. Caouette, 2019). De ahí, lo imperante de que las entidades financieras establezcan y realicen controles internos y otras prácticas para garantizar que las excepciones en las políticas, los procedimientos y límites son reportadas oportunamente al nivel gerencial apropiado.

El control de riesgos financieros con la gestión de un científico de datos implica el uso de técnicas y tecnologías avanzadas para supervisar y gestionar los riesgos asociados con las operaciones crediticias de una institución financiera

#### Validación de Controles de Provisiones de la Cartera por Segmentos de Crédito.

El objetivo de la validación de controles de provisión de la cartera de crédito es mantener la exposición al riesgo de crédito del banco dentro de los parámetros definidos por el directorio y la alta gerencia. La fijación y ejecución de controles internos, límites de operación y otras prácticas ayudará a garantizar que las exposiciones al riesgo de crédito no sean superiores a los niveles aceptables para el banco individual (Jorion, 2016).

#### Validación de Evolución de Segmentos de Cartera por Análisis de Cosechas.

Una razón para establecer un proceso de revisión sistemática del crédito es la identificación de créditos debilitados o con problemas. Una reducción en la calidad de crédito tiene que ser reconocida temprano, cuando hay más opciones disponibles para mejorar el crédito, por ello la importancia de implementar las revisiones de la cartera con cosechas elegidas según el análisis de la unidad de riesgo, estas cosechas contienen características específicas de segmento, plazo del crédito, monto y sector económico para evaluar su carácter de pago.

El análisis de cosechas es una metodología que permite observar y analizar el comportamiento o evolución de la cartera en el tiempo, tomando como aspecto principal el contexto en el que se dio la fase de colocación. Las cosechas se analizan tomando en cuenta el tipo de crédito, en este caso

se revisarán los segmentos comerciales, consumo y microcrédito, y consideran para su cálculo a la agrupación de los créditos cuya calificación se encuentra entre B y E tanto para el número de operaciones como para el saldo de créditos, al cual se denomina índice de calidad.

### Monitoreo De Riesgos Financieros

El monitoreo de riesgos financieros es un proceso continuo que implica supervisar de manera constante la salud financiera, de liquidez, operacional y el comportamiento crediticio de los prestatarios para identificar posibles señales de deterioro en su capacidad para cumplir con sus obligaciones crediticias. El objetivo principal es anticipar y gestionar cualquier riesgo potencial de incumplimiento antes de que se convierta en un problema grave (Wong, 2021).

El monitoreo de riesgos de crédito con inteligencia artificial (IA) (Alexander, 2016) implica utilizar técnicas y herramientas avanzadas para supervisar de manera continua la salud financiera y el comportamiento crediticio de los prestatarios, y para identificar señales tempranas de posibles problemas de incumplimiento.

### Modelo de Medición de Límites de Exposición y Alertas

Un elemento importante de la administración sana del riesgo de liquidez se refiere a discutir lo que podría ir mal en créditos individuales y en los diferentes segmentos e incluir esta información como un factor en el análisis de la conformidad del capital que debe ingresar como liquidez para fortalecer a la intermediación financiera.

Los límites de exposición (Bart Baesens, 2017) tienen que garantizar que la otorgación de crédito superior a ciertos niveles preestablecidos se señala inmediatamente a la gerencia, así como el monitoreo de límites adecuados permite a la gerencia controlar las exposiciones al riesgo, inicie discusiones sobre oportunidades y riesgos y monitoree los mismos frente a las tolerancias predeterminadas por la entidad (Colquitt, 2018).

### Modelo de Medición de Probabilidades de Default con Matrices de Transición

Las matrices de transición de crédito/incumplimiento (también conocidas como “matrices de

---

migración de crédito”) juegan un importante rol en la administración del riesgo de crédito. Las probabilidades asociadas a la transición de las calificaciones, en particular la probabilidad de default, el cual es un insumo básico para calcular la pérdida esperada y el capital económico (Hull, 2014).

Este concepto también es crucial en el cálculo del requerimiento de capital bajo el marco de Basilea. Respecto a las inversiones, estas matrices permiten la comparación y el pronóstico del nivel de exposición a pérdidas causadas por incumplimiento y devaluación debido a movimientos de difusión crediticia.


En términos simples, una matriz de transición de crédito está compuesta por "k" categorías de crédito (calificaciones o escalas) de las cuales "k-2" se encuentran en un estado de no-incumplimiento, una de ellas está en un estado de incumplimiento y una en estado de falta de información ("NR" o "Not Rated") (Gourieroux, 2014). Cuando la capacidad crediticia del deudor cambia, la entidad puede subir o bajar la calificación ("upgrade" o "downgrade", respectivamente). La matriz de transición refleja la probabilidad de que una emisión o compañía calificada en una categoría base pueda migrar hacia otra categoría de riesgo dentro de un período específico de tiempo; esto es llamado el “intervalo de transición”.


### **Inteligencia Artificial En Ciencia De Datos**

Una vez que se ha analizado las fases del ciclo de gestión de riesgos financieros, se evidencia de manera clara la necesidad de aplicar herramientas de software que puedan ser utilizadas en la implementación de soluciones de Ciencia de Datos, donde la Inteligencia Artificial juega un rol estratégico en la gestión de riesgos financieros. Estas herramientas ofrecen capacidades de modelado, análisis de datos y automatización que son cruciales para abordar los desafíos en esta área. Algunas de estas herramientas incluyen Python, que es uno de los lenguajes de programación más utilizados en la comunidad de Inteligencia Artificial y Ciencia de Datos, cuenta con bibliotecas como Scikit-learn, TensorFlow y Keras que permiten construir y entrenar

modelos de aprendizaje automático. En esta misma línea, R es otro lenguaje de programación ampliamente utilizado en estadísticas y análisis de datos que ofrece bibliotecas como caret, random Forest y xgboost para la construcción de modelos.

La aplicación de la Inteligencia Artificial En Ciencia De Datos para la Gestión de Riesgos Financieros demanda un meticuloso proceso de elección de la herramienta de software. Las consideraciones principales para la elección de herramientas incluyen la facilidad de uso, la capacidad de integración con otros sistemas, el soporte de la comunidad, la escalabilidad y la adecuación para los objetivos específicos de la implementación de nuevas tecnologías en la gestión de riesgos. Mientras que, para la implementación de las diversas herramientas de Gestión de Riesgos Financieros se propone el siguiente flujo de trabajo:





Sin embargo, es importante tener en cuenta que la implementación exitosa de la Inteligencia Artificial en la Ciencia de Datos para la gestión de riesgos financieros también conlleva desafíos. Estos incluyen datos de alta calidad, la interpretación de los resultados generados por algoritmos complejos, la consideración de aspectos éticos y de privacidad, y la capacitación de personal para comprender y utilizar eficazmente las herramientas de Ciencia de Datos.

## CONCLUSIONES

El uso de la Ciencia de Datos para la evaluación y gestión de riesgos ha transformado significativamente la forma en que las instituciones financieras abordan estos desafíos, ha demostrado ser una herramienta valiosa para mejorar la precisión, la eficiencia y la capacidad de respuesta en un entorno financiero cada vez más complejo; sin embargo, el éxito de su implementación depende de una comprensión sólida de los datos, las técnicas de IA y la capacidad de aplicarlos de manera efectiva en el contexto específico de cada institución.

La Ciencia de Datos ha demostrado ser capaz de analizar datos complejos y patrones sutiles que pueden no ser evidentes para los métodos tradicionales; esto ha llevado a una mayor precisión en

la evaluación de la capacidad crediticia de los prestatarios y en la predicción de incumplimientos sobre todo para los análisis de pérdida esperada.

La automatización de procesos de evaluación crediticia y monitoreo mediante la Ciencia de Datos ha permitido a las instituciones financieras agilizar sus operaciones y reducir la necesidad de intervención manual en tareas repetitivas, ya que los modelos desarrollados con técnicas de Ciencia de Datos pueden identificar señales tempranas de posibles problemas crediticios, lo que permite a las instituciones tomar medidas preventivas antes de que los riesgos se conviertan en problemas graves.

La Ciencia de Datos permite una mayor personalización en la toma de decisiones crediticias, ya que puede analizar datos individuales y adaptar las condiciones y los límites de crédito a las necesidades y la capacidad de cada prestatario, debido a la capacidad de la IA para analizar datos en tiempo real y ajustarse a condiciones cambiantes lo que permite una gestión más proactiva de los riesgos, lo que puede ayudar a minimizar pérdidas.

En resumen, la Ciencia de Datos ha tenido un impacto innegable al mejorar la precisión en la evaluación de la solvencia crediticia y la predicción de incumplimientos. La automatización resultante ha agilizado las operaciones y permitido la toma de medidas preventivas ante riesgos emergentes. A pesar de estos beneficios, el éxito de su implementación depende de una sólida comprensión de los datos y la capacidad de aplicar eficazmente las técnicas de IA en el contexto de cada institución financiera.

## Referencias

- Alexander, C. (2016). *Market Risk Analysis: Quantitative Methods in Finance*.
- Allen, A. S. (2021). *Credit Risk Measurement: New Approaches to Value at Risk and Other Paradigms*.
- Allen, S. L. (2017). *Gestión de Riesgos Financieros*.
- Bart Baesens, D. R. (2017). *Credit Risk Analytics: Measurement Techniques, Applications, and Examples in SAS*.
- Colquitt, J. (2018). *Credit Risk Management: How to Avoid Lending Disasters and Maximize Earnings*.
- Gourieroux, S. B. (2014). *Handbook of Credit Risk Management: Originating, Assessing, and Managing Credit Exposures*.
- Hull, J. C. (2014). *Risk Management and Financial Institutions*.
- John B. Caouette, E. I. (2019). *Managing Credit Risk: The Next Great Financial Challenge*.
- Jorion, P. (2016). *Value at Risk: The New Benchmark for Managing Financial Risk*.
- Koulafetis, P. (2017). *Modern Credit Risk Management: From Theory to Practice*.
- Lando, D. (2016). *Credit Risk Modeling: Theory and Applications*.
- Prado, M. L. (2021). *Machine Learning for Credit Scoring*.
- Rennie, I. L. (2017). *The Oxford Handbook of Credit Derivatives*.
- Tony Van Gestel, B. B. (2019). *Credit Risk Management: Basic Concepts: Financial Risk Components, Rating Analysis, Models, Economic and Regulatory Capital*.
- Wong, N. H. (2021). *Handbook of Financial Risk Management: Simulations and Case Studies*.