



FACULTAD DE
CIENCIAS ECONÓMICAS
Y DE ADMINISTRACIÓN

POSGRADOS



UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY

**UNIVERSIDAD DE LA REPÚBLICA
FACULTAD DE CIENCIAS ECONÓMICAS Y DE ADMINISTRACIÓN**

**TRABAJO FINAL PARA OBTENER EL TÍTULO DE
MAGÍSTER EN SISTEMAS DE INFORMACIÓN**

Título

**Hacia una nueva evaluación crediticia en la Era Fintech
Fundamentos para un modelo alternativo de *scoring* con Inteligencia Artificial en
Uruguay**

por

Noelia de los Santos

Joaquin Rubio

TUTOR: Myrian Errecalde

Montevideo

URUGUAY

2025

Agradecimientos

A la Universidad de la República, por toda la infraestructura que nos ha brindado para el desarrollo de la investigación. Especialmente al profesor Gabriel Budiño por llevar adelante la coordinación de la Maestría y estar siempre atento a la necesidad de los estudiantes.

A los entrevistados que colaboraron con información valiosa para la realización de este proyecto.

A los colegas, amigos y docentes, por el intercambio de conocimientos. Especialmente a Myrian la tutora del trabajo.

A todas las demás personas que no fueron citadas, pero que de alguna manera directa o indirecta contribuyeron a la realización de este trabajo final.

A nuestras familias por su apoyo incondicional.

Resumen

Esta investigación examina las oportunidades y desafíos de la implementación de inteligencia artificial (IA) en los sistemas de evaluación crediticia en América Latina, con foco específico en el contexto uruguayo. El estudio aborda la brecha existente entre el potencial transformador de las tecnologías de IA y su limitada adopción práctica en procesos críticos de *scoring* crediticio en la región.

La revisión sistemática de literatura reveló una marcada concentración de aplicaciones de IA en funciones de atención al cliente, evidenciando una carencia significativa de modelos efectivos orientados específicamente a la evaluación de riesgo crediticio. En el mercado uruguayo, los sistemas de *scoring* vigentes mantienen una dependencia predominante de metodologías tradicionales, particularmente regresión lineal.

El trabajo de campo, desarrollado mediante entrevistas semiestructuradas con actores clave del ecosistema financiero nacional —incluyendo directivos tecnológicos, representantes regulatorios y líderes de instituciones financieras tradicionales y *fintechs*—, confirmó la ausencia práctica de implementaciones específicas de IA en *scoring* crediticio. Este hallazgo, que contrasta con las hipótesis iniciales del estudio, evidencia un sector en fase incipiente de innovación tecnológica y configura una ventana de oportunidad estratégica para el desarrollo de soluciones contextualmente adaptadas.

Como contribución principal, se propone un marco metodológico integral para el diseño e implementación de modelos de *scoring* crediticio basados en IA, que integra criterios de efectividad predictiva, transparencia algorítmica y consideraciones éticas. Este marco busca equilibrar la optimización técnica con las exigencias de responsabilidad social y regulatoria.

Las conclusiones del estudio establecen que la IA representa un potencial transformador para fortalecer la inclusión financiera, incrementar la precisión predictiva de las evaluaciones

crediticias y promover relaciones más equitativas entre instituciones financieras y usuarios finales. Sin embargo, la materialización de estos beneficios requiere una implementación estratégica que considere las especificidades del contexto normativo, económico y social uruguayo, así como el desarrollo de capacidades institucionales adecuadas para la gestión responsable de tecnologías avanzadas.

Palabras clave: *scoring* crediticio, inteligencia artificial, inclusión financiera

Definiciones sugeridas para conceptos clave

1. *Sandboxes* regulatorios: Los *regulatory sandboxes* son entornos controlados promovidos por autoridades financieras en los que empresas Fintech pueden experimentar productos, servicios o modelos de negocio innovadores con usuarios reales, bajo una supervisión flexible y acotada en riesgos. Estos espacios permiten a los reguladores entender mejor las nuevas tecnologías y adaptar sus marcos normativos a la innovación financiera sin comprometer la estabilidad del sistema ni la protección al consumidor (Zetzsche et al., 2017).

2. Cámara de Compensación Automatizada (ACH) de carácter público:

Una Cámara de Compensación Automatizada (*Automated Clearing House*, ACH) es una infraestructura digital centralizada que facilita el intercambio, procesamiento y liquidación de pagos electrónicos entre instituciones financieras. Cuando es de carácter público, esta plataforma es operada o regulada por el Estado como bien público, promoviendo menores costos de transacción, mayor inclusión financiera, y acceso equitativo a servicios de pagos básicos (CGAP, 2021). Además, constituye una base sólida para la interoperabilidad y la innovación en sistemas de pagos abiertos y digitales.

3. API (Interfaz de Programación de Aplicaciones)

Una *API* (por sus siglas en inglés, *Application Programming Interface*) es un conjunto de reglas y protocolos que permite que diferentes sistemas de software se comuniquen entre sí. En el contexto de las finanzas abiertas, las APIs son utilizadas para habilitar el acceso estandarizado, seguro y controlado a los datos financieros de los usuarios por parte de terceros autorizados, tales como Fintechs o bancos competidores. Estas interfaces son la base técnica que hace posible la interoperabilidad entre instituciones y el desarrollo de servicios financieros personalizados en tiempo real (OECD, 2020).

ÍNDICE

Agradecimientos	ii
Resumen	iii
Definiciones sugeridas para conceptos clave.....	v
ÍNDICE	vi
INTRODUCCIÓN	1
Planteamiento del Problema	2
Objetivos	3
Justificación y Relevancia del Estudio	4
Alcance y Limitaciones	5
Estructura de la Tesis.....	6
MARCO TEÓRICO	8
<i>Inteligencia Artificial y Evaluación Crediticia: Fundamentos Teóricos.....</i>	<i>8</i>
MARCO METODOLÓGICO	14
1. ESTRUCTURA DEL SECTOR FINANCIERO URUGUAYO	19
Panorama General del Sistema Financiero en Uruguay y América Latina	19
Transformación digital y finanzas abiertas	20
Modelos Tradicionales de Evaluación Crediticia	23
Principales Limitaciones y Desafíos de los modelos utilizados	25
2. INTELIGENCIA ARTIFICIAL Y SCORING DE CRÉDITO	28
Evolución Histórica del Scoring Crediticio con IA	30
El Caso Uruguayo	33
Principales Técnicas y Algoritmos.....	33
Modelos Estadísticos para el Cálculo de Scoring.....	33
3. COMPONENTES CONCEPTUALES DE UN SISTEMA DE SCORING BASADO EN IA	37
Fuentes de Datos y Variables Relevantes	37
Ingeniería de Características para Scoring Alternativo	38
Arquitectura de Alto Nivel del Sistema	38
Flujos de Proceso y Roles Involucrados.....	39
4. TRANSPARENCIA, ÉTICA Y SESGOS EN SCORING CON IA	41

Explicabilidad de Modelos (XAI)	42
Evolución Histórica de los Procesos de Decisión Crediticia	42
El Desafío de la Interpretabilidad	43
Inteligencia Artificial Explicable (XAI)	44
Identificación y Mitigación de Sesgos	45
Estrategias de Mitigación	46
Privacidad y Protección de Datos Personales	46
El Ecosistema de Datos en la Era Digital	46
Cumplimiento Normativo y Regulatorio en Uruguay	47
Hallazgos y desafíos en torno a Finanzas Abiertas, Datos Alternativos, Educación e	
Inteligencia Artificial para el <i>scoring</i> crediticio.	50
Finanzas Abiertas, Datos Alternativos	51
CONCLUSIONES	55
Implicaciones y Recomendaciones.....	58
Referencias.....	60

INTRODUCCIÓN

La inteligencia artificial (IA) ha transformado múltiples sectores de la economía global, siendo el sector financiero uno de los más impactados por esta revolución tecnológica. Sin embargo, en América Latina y, particularmente en Uruguay, la implementación de IA en procesos de evaluación crediticia presenta características distintivas que requieren análisis específicos.

A pesar del creciente interés en las aplicaciones de IA en el ámbito financiero, la literatura especializada evidencia una concentración predominante en el desarrollo de asistentes virtuales y *chatbots* para la atención al cliente o para el procesamiento de grandes volúmenes de datos, mientras que quedan en un segundo plano las aplicaciones en procesos críticos como la evaluación crediticia. Esta situación resulta particularmente evidente al examinar la realidad latinoamericana, donde los casos documentados de implementación de IA en *scoring* crediticio son escasos.

La revisión bibliográfica realizada identificó únicamente una referencia práctica documentada: el caso de la financiera Servicrédito SA en Bucaramanga, Colombia. Esta carencia de casos de estudio contrasta significativamente con la abundante literatura teórica sobre las potencialidades de la IA en el sector financiero. En el contexto uruguayo, específicamente, el Banco Central del Uruguay (BCU) ha publicado estudios sobre *scoring* crediticio (Dassati, 2023), pero estos se enfocan en modelos tradicionales (regresión lineal) utilizando datos del año 2014, anterior al auge de la IA generativa.

Las entrevistas exploratorias realizadas con actores clave del sector financiero uruguayo, incluyendo directores ejecutivos de financieras, desarrolladores de soluciones tecnológicas para el sistema financiero y gerentes bancarios, confirmaron que, aunque existen iniciativas de IA generativa en algunas áreas operativas, no se han desarrollado aplicaciones específicas para *scoring* crediticio. Esta situación contradice la hipótesis

inicial de los investigadores, quienes anticiparon encontrar un campo ampliamente desarrollado.

Planteamiento del Problema

El sistema financiero uruguayo presenta una particularidad en cuanto a la transparencia de sus procesos de evaluación crediticia. A diferencia de otros países, las instituciones financieras no están obligadas legalmente a fundamentar ante el cliente las decisiones de aprobación o rechazo de créditos, lo que genera un entorno de opacidad en los criterios de evaluación.

Esta opacidad se ve acentuada por el hecho de que la mayoría de las instituciones bancarias operantes en Uruguay son filiales de bancos internacionales que aplican metodologías desarrolladas por sus casas matrices, las cuales pueden no estar completamente adaptadas a las características específicas del mercado local. Adicionalmente, la discrecionalidad en la selección de variables y metodologías de análisis limita la posibilidad de desarrollar modelos estandarizados y transparentes.

En este contexto, surge la necesidad de investigar cómo la implementación de tecnologías de IA podría contribuir a la mejora de los sistemas de evaluación crediticia, tanto en términos de eficiencia operativa como de precisión predictiva y transparencia en los procesos de decisión. Es decir que en este estudio se intentará dar respuesta a cómo la inteligencia artificial puede mejorar los sistemas de evaluación crediticia en Uruguay y contribuir al desarrollo de modelos de *scoring* más eficientes y transparentes.

Preguntas Secundarias

1. ¿Cuáles son las características del mercado financiero uruguayo y qué modelos de evaluación crediticia se utilizan actualmente?

2. ¿Qué tipos de herramientas basadas en IA son aplicables a los sistemas tradicionales de *scoring* financiero?
3. ¿Cuáles son los componentes metodológicos necesarios para el diseño de un modelo de *scoring* crediticio basado en inteligencia artificial que integre criterios de efectividad predictiva, transparencia algorítmica y consideraciones éticas, y de qué manera puede este modelo contribuir al fortalecimiento de las relaciones a largo plazo entre entidades financieras y sus clientes?
4. ¿Cuáles serían los componentes fundamentales de un modelo de *scoring* basado en IA específicamente adaptado al contexto uruguayo?

Objetivos

Objetivo General

Identificar y analizar las oportunidades de mejora que la inteligencia artificial puede aportar a los procesos de evaluación crediticia en Uruguay, desarrollando las bases conceptuales para un modelo de *scoring* alternativo que optimice la eficiencia operativa y promueva a la inclusión financiera para incorporar más agentes al mercado con mejores oportunidades de acceso.

Objetivos Específicos

1. Caracterizar el mercado financiero uruguayo: Analizar la estructura del sector financiero local, identificando los modelos de evaluación crediticia actualmente implementados y sus limitaciones.
2. Evaluar tecnologías de IA aplicables: Explorar y clasificar las diferentes herramientas de inteligencia artificial que pueden integrarse en sistemas tradicionales de *scoring* financiero, evaluando su viabilidad técnica y operativa.

3. Diseñar un marco conceptual: Desarrollar los componentes teóricos de un modelo de *scoring* alternativo basado en IA, enfocado en la construcción de relaciones sostenibles entre clientes e instituciones financieras.
4. Analizar la aplicación de modelos desarrollados con *machine learning (ML-IA)*, mediante la exploración de la bibliografía existente sobre su complejidad, e identificar la necesidad de incorporar enfoques éticos y humanos en su estudio y desarrollo.

Justificación y Relevancia del Estudio

La presente investigación se fundamenta en la convergencia de tres factores críticos que justifican su desarrollo y relevancia: la relevancia profesional y sectorial, el vacío de conocimiento académico sobre el tema y el impacto práctico potencial tanto para las instituciones financieras como para los usuarios del sistema.

En primer lugar, la experiencia profesional del equipo investigador en los sectores tecnológico y financiero proporciona una perspectiva privilegiada para comprender las necesidades operativas reales del sector. Esta proximidad al entorno empresarial permite identificar oportunidades de mejora que pueden traducirse en beneficios tangibles para la industria.

En segundo lugar, la ausencia de estudios rigurosos sobre la aplicación de IA en *scoring* crediticio en el contexto uruguayo y regional representa una oportunidad significativa para contribuir al conocimiento académico. Aunque existe abundante literatura internacional sobre IA financiera, la especificidad de los mercados emergentes latinoamericanos requiere análisis contextualizado.

Por último, el desarrollo de un marco teórico-práctico para la implementación de IA en *scoring* crediticio puede beneficiar tanto a instituciones financieras como a usuarios del sistema, contribuyendo a procesos más eficientes, transparentes y equitativos.

La relevancia de este estudio se ve reforzada por el momento histórico en que se desarrolla, ya que coincide con la maduración de tecnologías de IA y el creciente interés del sector financiero uruguayo en procesos de transformación digital (Mordezki y Asociados, 2025).

Alcance y Limitaciones

Esta investigación se centra en el análisis del sistema financiero uruguayo, con extensiones conceptuales aplicables a la región latinoamericana. El estudio abarca tanto instituciones bancarias como no bancarias que ofrecen servicios de crédito, incluyendo cooperativas de ahorro y crédito, fintechs, financieras y casas comerciales.

El marco temporal del análisis comprende un amplio periodo que permite capturar tanto la situación pre-pandémica como los cambios acelerados en digitalización financiera posteriores a la crisis sanitaria global.

Las limitaciones surgen de factores tales como:

1. Acceso a información: La naturaleza confidencial de los algoritmos de *scoring* utilizados por las instituciones financieras puede limitar el acceso a información detallada sobre metodologías específicas.
2. Disponibilidad de datos: La implementación práctica de modelos de IA requiere grandes volúmenes de datos históricos que pueden no estar disponibles o accesibles para fines de investigación académica.

3. Rapidez de evolución tecnológica: El acelerado desarrollo de tecnologías de IA puede hacer que algunas conclusiones pierdan vigencia en períodos relativamente cortos.

Estructura de la Tesis

La presente tesis se organiza en cuatro capítulos que abordan de manera sistemática la problemática planteada, desarrollando un análisis integral desde la contextualización del problema hasta la propuesta de soluciones.

En el primer capítulo se analiza el sistema financiero latinoamericano y uruguayo, examinando los modelos tradicionales de evaluación crediticia y sus principales limitaciones y desafíos actuales en el contexto regional.

En el segundo capítulo se presentan los fundamentos teóricos de IA y *machine learning* aplicados al *scoring* crediticio, incluyendo la evolución histórica, principales técnicas algorítmicas y aplicaciones emergentes como el uso de redes sociales y open banking.

En el tercer capítulo se propone la arquitectura conceptual de un sistema de *scoring* alternativo, detallando fuentes de datos, ingeniería de características, arquitectura de alto nivel y flujos de proceso sin implementación técnica específica.

En el cuarto capítulo se abordan los aspectos críticos de explicabilidad, identificación y mitigación de sesgos, privacidad de datos y cumplimiento normativo, estableciendo las bases para una implementación ética y transparente en el contexto regulatorio uruguayo.

Por último, se presentan los principales hallazgos y desafíos relacionados con las finanzas abiertas, Datos Alternativos, Educación e Inteligencia Artificial para el *scoring* crediticio.

En las conclusiones se sintetizan las aportaciones principales del estudio, se reconoce las limitaciones de la investigación y se presenta los principales retos y oportunidades identificados para el desarrollo futuro del *scoring* crediticio con IA en Uruguay.

MARCO TEÓRICO

Inteligencia Artificial y Evaluación Crediticia: Fundamentos Teóricos

El avance de la inteligencia artificial (IA) y su incorporación en sistemas de decisión automatizada ha reconfigurado el modo en que se analizan y procesan datos en múltiples sectores. En el ámbito financiero, la IA se ha consolidado como una herramienta estratégica, particularmente en áreas como detección de fraude, atención al cliente y evaluación de riesgo crediticio (Jain, 2023). A efectos de este trabajo, definiremos la inteligencia artificial como la capacidad de un sistema computacional para replicar funciones cognitivas humanas, tales como el aprendizaje, la clasificación de patrones, la predicción y la toma de decisiones autónomas (Russell & Norvig, 2021).

La historia de la inteligencia artificial, desde sus fundamentos filosóficos hasta los desarrollos modernos, ha abarcado diversos enfoques y tecnologías.

Un hito temprano y fundamental en la historia de la IA ocurrió en 1943, con el trabajo de McCulloch y Pitts. Estos autores propusieron un modelo neuronal basado en la idea de que la actividad nerviosa puede ser tratada mediante la lógica proposicional. Su modelo se fundamentó en consideraciones específicas sobre el comportamiento de las neuronas: la actividad de "todo o nada", la necesidad de un número fijo de sinapsis excitadas para disparar, el retardo sináptico como el único significativo, la acción absoluta de las sinapsis inhibitorias, y la estructura de la red que no cambia con el tiempo (McCulloch & Pitts, 1943).

La actividad de cualquier neurona podría representarse como una proposición, y las relaciones fisiológicas correspondían a relaciones lógicas. McCulloch y Pitts demostraron que cualquier expresión lógica finita podía ser realizada por neuronas de este tipo. Este modelo fue el primer modelo neuronal moderno y ha servido de inspiración, aunque no constituye un modelo adecuado de las neuronas biológicas reales. Su influencia teórica

fue inmensa en las ciencias de la computación, mostrando que elementos simples conectados en red podrían tener un gran poder computacional.

Los modelos de lenguaje de IA son un componente clave del procesamiento del lenguaje natural (NLP, por sus siglas en inglés), que busca permitir que las computadoras comprendan y generen lenguaje humano. El NLP implica el desarrollo de algoritmos y modelos que procesan, analizan y generan texto o habla en lenguaje natural. Estos modelos se entrenan con grandes cantidades de datos, utilizando técnicas que van desde enfoques basados en reglas hasta modelos estadísticos y aprendizaje profundo (Jurafsky & Martin, 2025).

Las aplicaciones del NLP son diversas, incluyendo autocompletado de texto, conversión de texto a voz, traducción, chatbots, asistentes virtuales y reconocimiento de voz. Los modelos de lenguaje tienen el potencial de automatizar tareas en muchas categorías profesionales, incluso tareas altamente calificadas. Modelos como GPT-4 muestran rendimientos equivalentes a los de los humanos en pruebas estandarizadas (OpenAI, 2023). Se están desplegando en sectores como la administración pública, servicios de salud, servicios financieros y educación para aumentar la productividad y reducir costos.

El desarrollo de modelos de aprendizaje automático (machine learning, ML), especialmente aquellos capaces de operar con datos masivos y no estructurados, ha permitido ampliar la frontera de lo posible en materia de *scoring* crediticio. Estos sistemas no solo ofrecen mejoras en la precisión predictiva, sino que también habilitan una nueva lógica evaluativa, capaz de adaptarse a contextos dinámicos y considerar perfiles tradicionalmente excluidos del sistema financiero (Martínez Fernández, 2023).

Modelos Tradicionales de Scoring Crediticio

Los modelos de *scoring* crediticio constituyen herramientas fundamentales para la evaluación del riesgo financiero. Tradicionalmente, estos se han construido sobre bases estadísticas lineales como el análisis discriminante, la regresión logística o el modelo probit (Hosmer et al., 2013), operando sobre variables estructuradas obtenidas de registros crediticios formales.

Si bien han demostrado efectividad en contextos con alta bancarización y estabilidad económica, presentan serias limitaciones para capturar realidades complejas como las de América Latina, donde la informalidad laboral y la baja penetración financiera siguen siendo factores determinantes (Alonso-Robisco & Carbó, 2023). Como afirman Nuka y Osedahunsi (2024), estos modelos tienden a "penalizar sistemáticamente a quienes no participan del sistema formal, perpetuando ciclos de exclusión y dificultando el acceso al crédito de comunidades vulnerables" (p. 1189).

Los modelos tradicionales de evaluación crediticia han sido históricamente el principal instrumento utilizado por las instituciones financieras para estimar la probabilidad de cumplimiento de pago de un solicitante. Basados generalmente en metodologías estadísticas lineales, como la regresión logística y el análisis discriminante, estos modelos operan sobre variables cuantitativas estandarizadas tales como ingresos declarados, estabilidad laboral, nivel de endeudamiento y, principalmente, historial crediticio en registros formales.

Si bien estos enfoques han permitido a los bancos y entidades financieras sistematizar el análisis de riesgo, también presentan importantes limitaciones en cuanto a su capacidad explicativa en contextos socioeconómicos complejos, como los de América Latina. Como señalan Alonso-Robisco y Carbó (2023), estos modelos han demostrado una utilidad

razonable bajo condiciones de datos estables y homogéneos, pero su rigidez los vuelve poco adaptables a poblaciones con alta informalidad económica o escasa bancarización.

En efecto, uno de los principales problemas de estos modelos radica en el sesgo estructural de sus variables: al basarse en antecedentes formales de crédito y empleo, terminan excluyendo a grandes sectores de la población que, si bien pueden demostrar capacidad de pago a través de otras fuentes, no califican según los parámetros clásicos. Esta situación es particularmente crítica en América Latina, donde amplios segmentos de trabajadores informales, emprendedores o jóvenes sin historial crediticio quedan fuera del sistema financiero tradicional.

En este sentido, Nuka y Osedahunsi (2024) advierten que los modelos tradicionales han contribuido históricamente a la reproducción de inequidades financieras: "estos criterios penalizan sistemáticamente a quienes no participan del sistema formal, perpetuando ciclos de exclusión y dificultando el acceso al crédito de comunidades vulnerables" (p. 1189). Además, los autores destacan que prácticas como el *redlining* —históricamente documentadas en Estados Unidos pero replicables en otras formas en distintas latitudes— han institucionalizado la discriminación crediticia, afectando especialmente a minorías y habitantes de zonas periféricas.

Alternativas Basadas en IA y Scoring Inclusivo

En respuesta a las limitaciones antes descritas, han emergido modelos de *scoring* alternativo que incorporan inteligencia artificial y fuentes de datos no tradicionales, como el comportamiento digital, pagos de servicios, historial de alquileres, actividad en redes sociales o datos móviles (Fair Isaac Corporation, 2017; BCU & CUF, 2023). Estos modelos permiten evaluar a usuarios sin historial crediticio formal, utilizando proxies alternativos de solvencia financiera.

Desde el punto de vista metodológico, esta transformación implica una evolución desde los scorecards discretos hacia los denominados “scorecards líquidos”, donde las variables se representan mediante funciones continuas como los B-splines, lo cual mejora la capacidad de capturar matices y relaciones no lineales (Hoadley, 2000). Además, modelos como el gradient boosting o las redes neuronales artificiales han mostrado mejores desempeños en escenarios complejos, aunque su interpretabilidad sigue siendo un desafío importante (Goodfellow et al., 2016).

El uso de estos enfoques en el contexto uruguayo aún es incipiente, pero diversas iniciativas fintech ya exploran soluciones que integran IA para evaluar perfiles de riesgo de forma más flexible y dinámica, ampliando las oportunidades de inclusión financiera en sectores históricamente desatendidos (BCU & CUF, 2023).

Consideraciones Éticas, Explicabilidad y Marco Normativo

La implementación de modelos de IA en *scoring* crediticio exige atender no sólo a criterios de eficiencia predictiva, sino también a principios éticos y normativos. Los algoritmos pueden reproducir o amplificar sesgos existentes si no se diseñan bajo marcos de equidad robustos (Barocas et al., 2019; AI for Good Foundation, 2023). Esta preocupación ha dado origen al campo de la Inteligencia Artificial Explicable (XAI), el cual desarrolla metodologías como SHAP y LIME para descomponer las predicciones de los modelos en elementos comprensibles para usuarios y reguladores (Miller, 2019).

Además, los marcos legales deben acompañar estos avances tecnológicos. En Uruguay, la Ley 18.331 de Protección de Datos Personales establece principios fundamentales de consentimiento, seguridad y derecho a la impugnación de decisiones automatizadas, lo cual tiene implicancias directas para cualquier sistema de *scoring* que utilice IA (URCDP, 2008). Sin embargo, todavía persisten vacíos regulatorios sobre transparencia

algorítmica, auditoría de modelos y uso de datos alternativos, lo que plantea desafíos para una implementación ética y socialmente justa.

MARCO METODOLÓGICO

La presente investigación adopta un enfoque cualitativo con diseño exploratorio-descriptivo, orientado a comprender el estado actual, las limitaciones estructurales y las oportunidades de mejora en los sistemas de *scoring* crediticio en Uruguay, a partir de la potencial incorporación de inteligencia artificial (IA). Esta estrategia responde a la naturaleza del objeto de estudio, que se encuentra en una etapa incipiente de desarrollo a nivel local, con escasa documentación empírica sistematizada. Como sostiene Hernández Sampieri y otros (2014) la teoría, en este tipo de estudio, es un marco de referencia, pero se construye básicamente a partir de los datos empíricos obtenidos y analizados.

El carácter exploratorio se justifica en tanto se pretende relevar percepciones, prácticas y representaciones de los actores clave del sistema financiero uruguayo sobre la adopción de IA en procesos de evaluación crediticia (Hernández Sampieri *et al*, 2014). A su vez, el componente descriptivo permite caracterizar los modelos actualmente utilizados, sus fundamentos metodológicos y las brechas de transparencia, inclusión y eficacia que los atraviesan.

No se busca en esta etapa validar empíricamente un modelo funcional, sino diseñar un marco conceptual robusto, contextualizado y alineado con los desafíos regulatorios, éticos y técnicos que implica la automatización crediticia en mercados emergentes como el uruguayo. Por tal motivo, esta etapa contempla un diseño explicativo, que permite identificar los componentes que fundamentan el modelo propuesto.

El estudio tiene un alcance no experimental, transversal y de carácter teórico-aplicado, centrado en el análisis del sistema financiero uruguayo, con referencias comparadas a casos de América Latina. Se consideran tanto entidades bancarias como no bancarias —

cooperativas de crédito, financieras, *fintechs* y casas comerciales— que operan en el mercado de préstamos al consumo.

El análisis se limita a las etapas de diagnóstico, conceptualización y diseño teórico de un sistema de *scoring* basado en IA, sin avanzar hacia su implementación técnica ni su validación empírica. Asimismo, se pone especial énfasis en las implicancias normativas, la protección de datos personales y la explicabilidad algorítmica como dimensiones clave para cualquier desarrollo futuro.

Para el desarrollo del trabajo se recurrió a fuentes primarias y secundarias articuladas en tres grandes categorías:

1. Revisión bibliográfica especializada, que incluye estudios académicos recientes sobre modelos de evaluación crediticia, machine learning, XAI (explicabilidad en IA), sesgos algorítmicos y regulación de datos, tanto a nivel global como latinoamericano.
2. Documentación técnica e institucional, en particular informes del Banco Central del Uruguay (Dassatti, 2023), la Cámara Uruguaya de Fintech (BCU & CUF, 2023), marcos normativos como la Ley 18.331 de Protección de Datos Personales, y publicaciones de referencia como las de Fair Isaac Corporation (2017).
3. Entrevistas exploratorias semi-estructuradas a actores relevantes del ecosistema financiero local, entre ellos directores de entidades crediticias, desarrolladores de soluciones tecnológicas, gerentes de riesgo y expertos en regulación. Estas entrevistas aportaron insumos clave sobre el estado real de adopción tecnológica,

las limitaciones operativas, los criterios de evaluación actuales y las percepciones sobre la transparencia y eficacia de los modelos utilizados.

La entrevista desde un enfoque cualitativo es flexible y abierta. Se define como una reunión para conversar e intercambiar información entre el entrevistador y el entrevistado donde se prepara en una guía de asuntos o preguntas, pero el entrevistador tiene la libertad de introducir preguntas adicionales para precisar conceptos u obtener mayor información a medida que se desarrolla (Hernández Sampieri *et al*, 2014).

Entre los entrevistados se encuentran:

Dario Abadie, CEO de Deployer Argentina, con experiencia en el desarrollo de modelos de *scoring* alternativo y aplicación de inteligencia artificial a partir de fuentes de datos no tradicionales. [Ver perfil en linkedin.](#)

Diego Vallarino, economista y científico de datos con trayectoria en diseño de modelos predictivos y regulación algorítmica para organismos multilaterales e instituciones financieras. [Ver perfil en LinkedIn](#)

Fernando Panizza, CTO de Bantotal, empresa proveedora de core bancario. [Ver perfil en LinkedIn.](#)

Ignacio Carballo, director del Ecosistema de Programas Fintech y Finanzas Alternativas en la Universidad Católica Argentina (UCA), investigador y consultor en inclusión financiera y tecnologías emergentes. [Ver perfil en LinkedIn.](#)

Patricia Dopazo, al momento de la entrevista es Directora de Tecnología y Operaciones del Banco Santander Uruguay, con amplia experiencia en procesos tecnológicos del sector bancario tradicional. [Ver perfil en LinkedIn.](#)

Rafael Mantero, CEO de Paigo, fintech uruguaya especializada en crédito al consumo, con foco en automatización y escalabilidad de modelos de riesgo. [Ver perfil en LinkedIn](#).

Rodrigo Tumaián, cofundador y co-CEO de Prometeo, plataforma regional de open banking, y presidente de la Cámara Uruguaya de Fintech. [Ver perfil de LinkedIn](#).

Además, se entrevistaron a los siguientes referentes del Banco Central del Uruguay:

Verónica Villete. Gerente de Protección al Consumidor Financiero. [Ver perfil LinkedIn](#).

Christian Salvarrey: Gerente de Estrategia y Operativa, administrador de la base de datos de riesgos [Ver perfil LinkedIn](#).

Dardo Curti : Jefe del departamento de estudios. [Ver perfil en LinkedIn](#).

El análisis de la información se realizó mediante una estrategia de categorización temática cualitativa, que permitió identificar patrones, tensiones y oportunidades en torno al uso de IA en *scoring* crediticio. Las entrevistas fueron procesadas mediante codificación abierta, lo que habilitó el agrupamiento de contenidos según ejes analíticos previamente definidos: inclusión financiera, precisión predictiva, explicabilidad de modelos, marco normativo y percepción de riesgo tecnológico.

Los pasos realizados para analizar los datos fueron, en primer lugar, explorar los datos e imponerles una estructura para organizarlos en unidades y categorías. La descripción de las experiencias de los participantes según su óptica, lenguaje y expresiones; permite descubrir los conceptos, categorías, temas y patrones presentes en los datos, así como sus vínculos, a fin de otorgarles sentido, interpretarlos y explicarlos en función del planteamiento del problema. Luego, se vincularon los resultados obtenidos con el

conocimiento disponible, lo que permite generar una teoría fundamentada en los datos (Hernández Sampieri *et al*, 2014).

Es decir que se aplicó una triangulación de fuentes entre evidencia empírica (entrevistas), revisión bibliográfica y documentación institucional, con el fin de fortalecer la validez del análisis y enriquecer la propuesta conceptual del modelo. Esta triangulación permitió contrastar la perspectiva normativa con las prácticas reales del sector, y articular los avances académicos con las condiciones operativas del mercado uruguayo.

1. ESTRUCTURA DEL SECTOR FINANCIERO URUGUAYO

Panorama General del Sistema Financiero en Uruguay y América Latina

Aunque el análisis se enfoca en Uruguay, se incluye una contextualización del panorama latinoamericano de inteligencia artificial y finanzas abiertas para proporcionar una perspectiva integral que permita comprender la posición del país dentro del ecosistema regional e identificar las particularidades que caracterizan su desarrollo en este ámbito tecnológico.

El sistema financiero de América Latina ha atravesado un proceso sostenido de modernización en las últimas décadas, impulsado por la necesidad de ampliar la bancarización, mejorar la eficiencia operativa y enfrentar la creciente competencia de actores no tradicionales, como las *fintech*. Sin embargo, pese a los avances regulatorios y tecnológicos, persisten importantes desafíos vinculados al acceso equitativo al crédito, especialmente en lo que refiere a los préstamos al consumo para sectores históricamente excluidos del sistema formal.

En países como Uruguay, donde el mercado de crédito al consumo es dinámico, pero altamente concentrado, los criterios tradicionales de evaluación crediticia continúan siendo el principal filtro para la aprobación de solicitudes. Estos modelos, centrados en variables como historial crediticio, antigüedad laboral o tenencia de propiedad, tienden a reproducir lógicas de exclusión para segmentos informales, trabajadores independientes o personas sin historial bancario formal. Esta situación no es exclusiva de Uruguay. Como señalan Nuka y Osedahunsi (2024), "los métodos tradicionales de evaluación crediticia han marginado históricamente a comunidades desatendidas, perpetuando ciclos de exclusión y disparidad económica" (p. 1189).

La limitada capacidad de estos modelos para incorporar fuentes de información alternativa —como pagos de servicios, alquileres o actividad económica digital— dificulta la inclusión financiera de amplios sectores de la población. Esta brecha es especialmente visible en regiones donde predomina la informalidad laboral y el acceso a productos financieros depende de variables estructurales difíciles de modificar en el corto plazo.

Además, en muchos países de la región, incluido Uruguay, la normativa vigente no obliga a las instituciones financieras a fundamentar detalladamente los motivos detrás de la aprobación o rechazo de un crédito. Esto genera una dinámica de opacidad que afecta no solo la percepción del sistema por parte de los usuarios, sino también las posibilidades de mejorar los procesos evaluativos desde una lógica de equidad. Según Nuka y Osedahunsi (2024), esta falta de transparencia contribuye a mantener una estructura crediticia "que penaliza a quienes operan fuera del sistema financiero tradicional, aun cuando estos demuestren responsabilidad financiera por otros medios" (p. 1190).

En este contexto, la región se enfrenta al doble desafío de modernizar sus herramientas de análisis crediticio y, al mismo tiempo, hacerlo con criterios que permitan ampliar el acceso al crédito sin comprometer la solvencia del sistema. La inteligencia artificial surge como una oportunidad tecnológica con capacidad de transformar este panorama, aunque su adopción conlleva también riesgos y dilemas que deberán abordarse con una mirada crítica y responsable, como se desarrollará en los apartados siguientes.

Transformación digital y finanzas abiertas

La evolución del sistema financiero en América Latina ha estado marcada por procesos diferenciados de transformación digital, donde la adopción de tecnologías emergentes como la banca abierta, los pagos instantáneos y las criptomonedas ha generado cambios

estructurales. En este apartado se presenta un análisis comparativo de los casos de Argentina, Chile y Brasil, con énfasis en el impacto de dichas innovaciones en la inclusión financiera, la competencia y el comportamiento de los usuarios.

Argentina: digitalización en un contexto de volatilidad

El caso argentino se caracteriza por una fuerte adopción de soluciones tecnológicas por parte del sector privado, como respuesta a las restricciones del sistema financiero tradicional y a la alta inflación. En los últimos años, el uso de criptomonedas se ha generalizado como mecanismo de ahorro y reserva de valor. De hecho, Argentina es uno de los países con mayor adopción cripto a nivel mundial, posicionándose en el puesto número 15 en el índice global de Chainalysis (2023).

Plataformas locales como Ripio han ampliado su base de usuarios ofreciendo wallets cripto, acceso a tokens estables y herramientas de inversión. A su vez, el desembarco de Nubank en el país ha consolidado un ecosistema fintech centrado en la inclusión financiera, con productos 100 % digitales y sin comisiones.

En paralelo, iniciativas regulatorias como el sistema de Transferencias 3.0, impulsado por el Banco Central de la República Argentina (BCRA), permitieron el uso de códigos QR interoperables y pagos inmediatos, fomentando una mayor bancarización digital.

Chile: institucionalización de la innovación financiera

Chile ha adoptado un enfoque gradual y regulado hacia la innovación tecnológica en finanzas. La promulgación de la Ley N.º 21.521 de Innovación Financiera en 2023 sentó las bases para el desarrollo de un marco de finanzas abiertas, contemplando la figura de los Proveedores de Servicios de Información y de Iniciación de Pagos (PSIP). Esta normativa busca fomentar la competencia y la transparencia, habilitando la circulación

segura de datos financieros entre instituciones autorizadas (Ministerio de Hacienda de Chile, 2023).

El sistema financiero chileno, con altos niveles de bancarización, presenta una sólida infraestructura digital que facilita la integración de nuevos actores, incluyendo fintechs que ofrecen servicios de pagos, crédito y gestión financiera personal. El modelo chileno se destaca por su orientación a la protección del consumidor y la interoperabilidad, anticipando un proceso de apertura de datos similar al de otras economías más avanzadas.

Brasil: liderazgo regional en *Open Finance* y pagos instantáneos

Brasil constituye el caso más avanzado de la región en términos de integración tecnológica en servicios financieros. A partir de 2020, el Banco Central de Brasil lideró el desarrollo de un ecosistema de *Open Banking*, posteriormente ampliado a un modelo de *Open Finance*, que incluye productos como seguros, inversiones y pensiones (Banco Central do Brasil, 2023).

Open Banking puede definirse como “un sistema que permite a los usuarios compartir, de manera segura y con consentimiento explícito, sus datos financieros con terceros autorizados, generalmente a través de interfaces de programación de aplicaciones (APIs)” (Zetsche et al., 2022). *Open Finance*, por su parte, representa una evolución de este modelo, extendiendo el acceso y la capacidad de compartir datos a un espectro más amplio de productos y servicios financieros (Arner et al., 2021).

En este contexto, el lanzamiento de Pix, sistema de pagos instantáneos desarrollado por el Banco Central, ha sido clave. Pix permite transferencias 24/7, sin costo para personas físicas, con acreditación inmediata. Su adopción ha sido masiva: para mediados de 2024,

el sistema registró más de 140 millones de usuarios y una participación de más del 40 % en las transacciones digitales del país (Banco Central do Brasil, 2024).

Entre los impactos más relevantes se destaca la integración de Pix con el ecosistema de *Open Finance*, permitiendo servicios como el débito automático (Pix Automático), la portabilidad de productos y la personalización de ofertas crediticias. Esto ha impulsado nuevos modelos de negocio centrados en el usuario y una competencia más dinámica en el sector.

Modelos Tradicionales de Evaluación Crediticia

Los modelos tradicionales de evaluación crediticia, fundamentados en metodologías estadísticas lineales como la regresión logística, han constituido el mecanismo principal para estimar el riesgo crediticio mediante variables estandarizadas como ingresos, estabilidad laboral e historial crediticio formal. Sin embargo, estos enfoques presentan limitaciones significativas en contextos socioeconómicos complejos, particularmente en América Latina, donde su rigidez los hace poco adaptables a poblaciones con alta informalidad económica.

El sesgo estructural de estos modelos excluye sistemáticamente a sectores poblacionales que, aunque pueden demostrar capacidad de pago mediante fuentes alternativas, no califican según parámetros tradicionales. Esta situación afecta especialmente a trabajadores informales, emprendedores y jóvenes sin historial crediticio.

La situación en Uruguay refleja algunos de estos desafíos. A pesar de contar con un sistema financiero sólido, el *scoring* aplicado por bancos y financieras suele basarse en criterios opacos definidos por matrices internacionales o políticas corporativas internas, sin obligación regulatoria de transparentar los factores que determinan la aceptación o

rechazo de una solicitud. Esta opacidad no solo dificulta la auditoría social de estos modelos, sino que también impide al cliente conocer y mejorar sus condiciones de acceso. En palabras de Nuka y Osedahunsi (2024), "la ausencia de explicabilidad en los modelos tradicionales no solo limita la confianza de los usuarios, sino que además restringe su capacidad para desafiar o corregir decisiones injustas" (p. 1190).

El caso uruguayo refleja esta tensión: los sistemas de *scoring* utilizados por bancos y financieras operan en muchos casos como "cajas negras", sin transparencia normativa sobre las variables utilizadas ni obligación de explicar los rechazos a los solicitantes. Esta dinámica genera una asimetría de información que obstaculiza la inclusión financiera y limita la capacidad del solicitante para mejorar su perfil crediticio.

A nivel técnico, la literatura reciente sugiere que, si bien modelos como la regresión logística siguen mostrando buenos niveles de rendimiento, su capacidad de aprendizaje es limitada en comparación con algoritmos más complejos. Según Martínez Fernández (2023), modelos como el *Gradient Boosting* han mostrado ventajas claras en términos de precisión, especialmente cuando se dispone de conjuntos de datos amplios y heterogéneos. Sin embargo, su adopción aún es escasa en el sector bancario tradicional, en parte por barreras culturales, regulatorias y de gobernanza tecnológica.

En resumen, los modelos tradicionales de evaluación crediticia, si bien siguen siendo la base operativa de muchas entidades financieras en Uruguay y la región, presentan limitaciones estructurales tanto desde el punto de vista técnico como ético. Esta realidad habilita la exploración de nuevos enfoques, como los que ofrece la inteligencia artificial, capaces de incorporar variables alternativas, mejorar la precisión predictiva y contribuir a una mayor inclusión financiera, tal como se abordará en los próximos apartados.

Diversos actores del ecosistema financiero latinoamericano coinciden en que la implementación de inteligencia artificial en *scoring* crediticio aún se encuentra en una etapa temprana, con aplicaciones limitadas y desafíos estructurales importantes. Tumaíán (2024), CEO de Prometeo y presidente de la Cámara Fintech, señala que “los modelos actuales siguen usando regresión lineal y hay una alta estandarización de variables”, lo cual limita la capacidad de adaptación a contextos locales.

Principales Limitaciones y Desafíos de los modelos utilizados

A pesar de los avances tecnológicos y metodológicos en la industria financiera, los sistemas de evaluación crediticia enfrentan actualmente una serie de limitaciones que obstaculizan su capacidad para ofrecer resultados justos, precisos y adaptados a los nuevos contextos socioeconómicos. Estas restricciones se pueden clasificar en tres dimensiones principales: técnicas, sociales y ético-regulatorias.

Limitaciones Técnicas

Desde el punto de vista técnico, los modelos tradicionales de *scoring* presentan una escasa capacidad de adaptación a entornos de datos no estructurados o alternativos. Muchos de estos modelos se basan en supuestos lineales y en relaciones estáticas entre variables, lo que reduce su capacidad para capturar comportamientos dinámicos o no convencionales del usuario financiero. Si bien técnicas como el *Gradient Boosting* o el *Random Forest* han mostrado un mejor desempeño predictivo en entornos experimentales (Martínez Fernández, 2023), su implementación masiva en el sector financiero aún se encuentra restringida por la falta de capacidades analíticas, datos de calidad y cultura de innovación en las organizaciones financieras tradicionales.

Restricciones Sociales y Estructurales

En América Latina, y particularmente en Uruguay, el funcionamiento de los modelos crediticios se ve afectado por la estructura del mercado laboral y por altos niveles de informalidad. Esto implica que un significativo número de personas quedan excluidas de los circuitos formales de crédito, no por carecer de capacidad de pago, sino por no cumplir con los requisitos formales del *scoring* vigente. Como señalan Nuka y Osedahunsi (2024), "criterios como la historia crediticia o la propiedad de bienes excluyen sistemáticamente a individuos que operan fuera del sistema financiero formal" (p. 1189).

Además, estos modelos son insensibles a trayectorias financieras emergentes, como las generadas en economías digitales, trabajos por cuenta propia o ingresos no recurrentes. Este sesgo estructural refuerza patrones de exclusión, limitando el acceso al crédito y, por ende, las oportunidades de desarrollo económico de los sectores más vulnerables.

Desafíos Éticos y de Transparencia

Uno de los principales desafíos actuales radica en la opacidad de los modelos utilizados por bancos y financieras, tanto en su lógica de funcionamiento como en los criterios que definen la aprobación o rechazo de un crédito. Esta falta de transparencia no solo genera desconfianza por parte de los usuarios, sino que impide el escrutinio técnico y social necesario para garantizar procesos justos. En Uruguay, por ejemplo, no existe una normativa que obligue a las instituciones a fundamentar ante el solicitante los motivos del rechazo, lo que deja al cliente sin herramientas para mejorar su perfil crediticio.

Por otro lado, el surgimiento de sistemas de inteligencia artificial agrega un nuevo nivel de complejidad. Si bien estos modelos tienen la capacidad de mejorar la precisión y ampliar la base de datos utilizada para el análisis, también presentan riesgos considerables en términos de sesgos algorítmicos y falta de explicabilidad. Como explican Nuka y Osedahunsi (2024), "los modelos de IA pueden replicar patrones históricos de

discriminación si no se diseñan con marcos éticos robustos y principios de equidad integrados desde el inicio" (p. 1191).

Brechas Regulatorias

Finalmente, la evolución de los modelos crediticios enfrenta el reto de adaptarse a un entorno regulatorio que muchas veces resulta obsoleto frente al ritmo del cambio tecnológico. Las legislaciones sobre protección de datos, auditoría de algoritmos y uso de información alternativa en evaluaciones financieras se encuentran en desarrollo o directamente ausentes en muchos países de la región. Esta situación genera incertidumbre jurídica tanto para los desarrolladores de tecnología como para las instituciones financieras y los usuarios.

2. INTELIGENCIA ARTIFICIAL Y SCORING DE CRÉDITO

En América Latina —y particularmente en Uruguay—, la implementación de IA en evaluación crediticia se encuentra en una etapa incipiente. Como señala Dassatti (2023), la mayoría de las instituciones locales aún utilizan modelos tradicionales centrados en criterios clásicos como el historial de pagos, la antigüedad laboral o el nivel de ingresos, lo que genera una barrera estructural para segmentos sin historial bancario formal. Esta situación ha llevado a que numerosos actores del ecosistema financiero y fintech comiencen a explorar modelos alternativos, más inclusivos y adaptables.

En un entorno cada vez más gobernado por métricas cuantitativas, donde cada interacción se traduce en "*likes*", reproducciones o clics, surge la necesidad de entender cuánto de esa lógica (la representación del comportamiento en una cifra) se aplica al ámbito financiero. En este capítulo, se revisa el origen y evolución de la inteligencia artificial aplicada al *scoring*, desde sus primeros modelos estadísticos hasta los algoritmos de *machine learning* actuales. Se analizan no sólo los usos tradicionales (aprobación de préstamos y segmentación de clientes), sino también nuevas aplicaciones como el *scoring* alternativo basado en datos de redes sociales y banca abierta. Se abordan además aspectos críticos como la transparencia de los modelos, la mitigación de sesgos, la protección de datos personales y el cumplimiento normativo. Finalmente, se evalúa el impacto de estas calificaciones en distintas regiones —desde mercados maduros con regulaciones estrictas hasta economías emergentes en búsqueda de inclusión financiera—, concluyendo con recomendaciones para optimizar su utilidad y garantizar su equidad.

Carballo (2024) advierte que muchas empresas “sobrevenden capacidades de IA sin impacto real en el negocio”, y que el *scoring* alternativo basado en IA requiere tanto la generación de mejores datos como el desarrollo de algoritmos realmente explicables. Por su parte, Mantero (2024), CEO de Paigo, destaca el trade-off entre precisión y

trazabilidad, alertando que “los modelos más precisos son también los más opacos”, y que esto representa un problema para la gobernanza y la sustentabilidad operativa de estos sistemas.

Desde una perspectiva institucional, Dopazo (2024), del Banco Santander Uruguay, indica que aunque los bancos grandes tienen acceso privilegiado a la base de la Central de Riesgos del BCU, “no están aplicando IA sobre esos datos”. Las decisiones de riesgo siguen guiadas por políticas de casas matrices, con poco margen para el desarrollo de modelos adaptados al mercado uruguayo.

Dario Abadie (comunicación personal, 2024), CEO de Deployer, aportó una visión práctica sobre la expansión del *scoring* crediticio a través de fuentes no tradicionales. Relató experiencias en las que se incorporaron datos como los mensajes SMS del solicitante o videos donde las pequeñas empresas explican su modelo de negocio. En este último caso, se utilizaron modelos de procesamiento de lenguaje natural (NLP) para interpretar la información brindada oralmente, generando puntajes a partir del contenido expresado. Este tipo de enfoques refleja la capacidad de la inteligencia artificial para trabajar con datos no estructurados y ofrecer alternativas al modelo tradicional de evaluación financiera.

Riesgos y Consideraciones Éticas

Los riesgos asociados con los modelos de lenguaje de IA constituyen una preocupación importante. La complejidad y opacidad de muchos modelos basados en redes neuronales dificultan la comprensión de su funcionamiento interno y cómo llegan a resultados específicos, lo que puede llevar a la imprevisibilidad y dificultar la determinación de responsabilidades.

Existen riesgos para los derechos humanos, la privacidad, la equidad, la robustez, la seguridad y la protección. Los datos de entrenamiento pueden incluir sesgos, información confidencial o información protegida por propiedad intelectual. Los modelos pueden discriminar, divulgar información confidencial o infringir derechos. Pueden facilitar la manipulación de opiniones a gran escala y automatizar la desinformación, amenazando los valores democráticos y la confianza ciudadana.

La explicabilidad en IA es un área de investigación que busca abordar la naturaleza de "caja negra" de algunos modelos de aprendizaje automático. Se basa en ideas de la filosofía, psicología y ciencia cognitiva. Las explicaciones deben ser contrafactuales (mostrar por qué sucedió un evento en lugar de otro), selectivas (centrarse en las causas clave) y constituir una conversación social adaptada al modelo mental del usuario.

Evolución Histórica del Scoring Crediticio con IA

Antecedentes del Score Crediticio

Durante mucho tiempo, antes de la existencia del puntaje de crédito, las decisiones sobre la concesión se basaban en el juicio personal de los prestamistas. La necesidad de contar con un patrón común de aprobación o rechazo, sumada a la escasez de personal calificado durante la guerra, determinó la realización de un sistema de puntuación que pudiera ser aplicado de forma indistinta, conduciendo a los mismos resultados.

En 1941, Durand publicó un artículo pionero en el que sugirió que era posible predecir qué solicitantes podrían incumplir con sus pagos, mediante un análisis sistemático de las características de aquellos que lo habían hecho en el pasado (Durand, 1941). Sin embargo, no fue hasta 1958 cuando se implementó el primer sistema de puntaje de crédito para una empresa financiera en Estados Unidos (Fair Isaac Corporation), marcando un hito en la evaluación crediticia.

En Estados Unidos, el puntaje de crédito puede determinar el acceso a un préstamo con una tasa de interés variable. Esta evaluación también se utiliza para determinar la elegibilidad como inquilino o el precio del seguro del automóvil. En Estados Unidos, varias empresas analizan el score, pero el capítulo se centra en la información proporcionada por Fair Isaac Company (FICO), una de las más utilizadas.

El score se basa en los informes de crédito de las agencias de reporte del consumidor (*Consumer Reporting Agency*, CRA) y analiza cinco puntos clave con la siguiente ponderación:

Historial de pagos (35%): Este apartado evalúa la puntualidad en los pagos. Incluye tarjetas de crédito internacionales como Visa, MasterCard y American Express, así como tarjetas emitidas por comercios minoristas. Además, se analiza el cumplimiento de los pagos de préstamos del solicitante, tales como hipotecas y préstamos para automóviles. También se considera otra información pública relacionada con el riesgo de incumplimiento, como quiebras y demandas judiciales.

Montos adeudados (30%): Se evalúa qué porcentaje del crédito está siendo utilizado por el consumidor en relación con su límite total. Esta evaluación se realiza tanto de forma conjunta como individual para cada línea de crédito. Las investigaciones muestran que cuanto mayor es el porcentaje de uso de una línea de crédito, existe un mayor riesgo potencial de caer en mora.

Duración del historial de crédito (15%): Refleja el tiempo durante el cual el consumidor ha mantenido cuentas de crédito abiertas.

Crédito nuevo (10%): Considera las solicitudes recientes de crédito. Un número elevado de solicitudes en un corto período reduce la atractividad del usuario para las empresas de

crédito, exceptuando las solicitudes de créditos hipotecarios, de auto y de estudios realizadas en un plazo de 30 días.

Tipos de crédito en uso (10%): Examina la variedad de créditos que posee el consumidor, desde diferentes tarjetas hasta préstamos a largo plazo.

Es pertinente reflexionar sobre lo que sucede cuando no se tiene historial crediticio, lo cual puede constituir una limitante importante, ya que estas tres cifras pueden determinar gran parte de la vida de una persona. Esto genera un sesgo implícito que perjudica a las personas que migran, ya que pueden tener muy buen historial en su lugar de origen, pero este no se considera en los reportes de crédito de los países destino. Por otro lado, también existe un sesgo basado en el origen familiar del solicitante, ya que aquellos provenientes de familias con mayores recursos probablemente ingresen a una edad más temprana al sistema financiero con apoyo de sus padres, lo que les permite construir una historia de crédito positiva en la que apoyarse en el futuro.

Marco Regulatorio: Transparencia vs. Opacidad

La Ley de Informe Justo del Crédito (*Fair Credit Reporting Act* de 1970, 15 U.S.C. § 1681 et seq.) establece que, en Estados Unidos, cuando se deniega un crédito o se otorgan términos no favorables, debe explicarse qué puntaje de crédito se ha utilizado y qué empresa lo ha proporcionado.

Adicionalmente, la Oficina de Protección Financiera del Consumidor (CFPB) supervisa y regula a las empresas de crédito, garantizando que los modelos de *scoring* se empleen de manera justa y sin discriminación. La CFPB puede requerir a las empresas de crédito que proporcionen información sobre sus modelos de *scoring* si se sospecha que estos podrían estar violando las leyes de protección al consumidor.

El Caso Uruguayo

Según Dassatti (2023), basado en una encuesta realizada en 2014 por el Banco Central del Uruguay, las Empresas Administradoras de Crédito (EAC) se clasifican según sus activos. Aquellas con mayores activos deben cumplir con la condición de que la suma de los activos totales más contingencias de la institución al cierre del ejercicio supere el equivalente a 100,000 Unidades Reajustables.

El 57% de las EAC con mayores activos tenía implementado un modelo de *scoring* para las decisiones de admisión u originación de créditos. En contraste, solo un 14% declaraba contar con un *score* de comportamiento para evaluar el riesgo crediticio de los clientes existentes. Un 33% restante estaba considerando implementar algún modelo de score crediticio.

En cuanto a las variables utilizadas, la mayoría incluía entre 5 y 10, donde la edad, el nivel de ingresos y los antecedentes crediticios eran las más importantes para la concesión del crédito. En las EAC menores, un 50% declaraba contar con modelos de puntaje crediticio, mientras un 43% expresaba su intención de incorporar uno en el futuro.

Principales Técnicas y Algoritmos

Modelos Estadísticos para el Cálculo de Scoring

Modelos Lineales

Análisis Discriminante: Se utiliza para clasificar a los clientes que solicitan crédito en grupos definidos previamente (por ejemplo, buenos y malos pagadores). Este modelo busca la combinación óptima de variables que maximicen las diferencias entre los grupos

Probabilidad Lineal: Este modelo aplica regresión lineal para predecir la probabilidad de que un cliente incumpla sus obligaciones crediticias. Aunque es fácil de interpretar,

presenta limitaciones en su uso práctico debido a la naturaleza binaria de la variable dependiente (cumple/incumple).

Modelos No Lineales

Modelo Logit: Este modelo es ampliamente utilizado para problemas de clasificación en *scoring*. Es una técnica estadística multivariante que estima la probabilidad de un evento binario (por ejemplo, la probabilidad de incumplimiento del pago)

Modelo Probit: Similar al modelo logit, el modelo probit asume una distribución normal para la variable dependiente. Es útil cuando se requiere modelar la relación entre la variable dependiente y las variables explicativas de manera no lineal.

Modelos No Paramétricos

Estos modelos no asumen una forma funcional específica para la relación entre las variables explicativas y la variable de interés. En lugar de eso, utilizan formas funcionales flexibles que se ajustan a los datos.

Redes Neuronales: Este método se inspira en el funcionamiento del cerebro humano, utilizando nodos interconectados que aprenden patrones de los datos. Presentan alta capacidad predictiva, especialmente en muestras pequeñas, y no requieren conocimientos previos sobre las relaciones entre las variables. Sin embargo, son difíciles de interpretar y comprender, ya que operan como una "caja negra" (Goodfellow et al., 2016).

Árboles de Decisión: Son una técnica de clasificación que divide los datos en ramas para tomar decisiones basadas en las características del solicitante. Son fáciles de interpretar y visualizar, y no requieren suposiciones previas sobre la distribución de los datos. No obstante, existe el riesgo de sobreajuste (*overfitting*), donde el modelo puede ajustarse

demasiado bien a los datos específicos, reduciendo su capacidad para generalizar (James et al., 2021).

Incorporación de la Tecnología al Cálculo de los Modelos

La inteligencia artificial está transformando la industria financiera globalmente, y Latinoamérica no es la excepción. Según Jain (2023), varios sectores se han visto impactados positivamente con la introducción de esta tecnología:

- **Detección de Fraude:** Los algoritmos de IA analizan grandes volúmenes de datos transaccionales en tiempo real, identificando patrones anómalos y posibles actividades fraudulentas con mayor precisión y rapidez que los sistemas tradicionales.
- **Calificación Crediticia:** Los modelos de calificación crediticia basados en IA utilizan algoritmos de aprendizaje automático para considerar una amplia gama de variables y datos históricos, permitiendo evaluaciones de riesgo más precisas.
- **Servicio al Cliente:** Los asistentes virtuales impulsados por IA, como los chatbots, ofrecen soporte personalizado y eficiente a los clientes.

En el contexto del *scoring* crediticio, la IA utiliza algoritmos avanzados y técnicas de *machine learning* (ML) para analizar grandes volúmenes de datos y predecir el comportamiento crediticio de los individuos. Según Martínez Fernández (2023), los algoritmos que mejor funcionan son Regresión Logística y Gradient Boosting, considerando siempre la calidad, cantidad de datos y el contexto del negocio.

Desde una mirada tecnológica aplicada al sector bancario, Fernando Panizza (CTO de Bantotal) plantea que la inteligencia artificial debería concebirse no sólo como una herramienta para optimizar lo existente, sino como un motor para redefinir

completamente cómo se diseñan las soluciones financieras. En su visión, "no hay que hacer lo mismo con otra herramienta, sino buscar nuevas maneras que la inteligencia artificial permite", haciendo énfasis en la capacidad de analizar lenguaje natural, imágenes o patrones conductuales que antes eran inaccesibles (Panizza, comunicación personal, 2025).

3. COMPONENTES CONCEPTUALES DE UN SISTEMA DE SCORING BASADO EN IA

Fuentes de Datos y Variables Relevantes

Un sistema moderno de evaluación crediticia basado en inteligencia artificial integra múltiples fuentes de datos que superan el enfoque tradicional de los modelos clásicos. Históricamente, los modelos de score crediticio, como el FICO®, se han construido sobre variables extraídas de reportes de crédito (Fair Isaac Corporation, 2017).

Sin embargo, ante la necesidad de ampliar el acceso al crédito y reducir los sesgos históricos, han surgido sistemas de *scoring* alternativo que incorporan datos no tradicionales. Estos incluyen pagos de servicios públicos, historial de alquileres, comportamiento digital, información derivada del uso de dispositivos móviles, geolocalización y redes sociales. La inclusión de estas fuentes ha demostrado ser útil para incorporar a individuos con poca o nula historia crediticia al sistema financiero formal.

En el contexto uruguayo, la industria *fintech* ha experimentado un crecimiento sostenido, impulsado en parte por la incorporación de herramientas basadas en inteligencia artificial para la mejora de procesos crediticios. De acuerdo con el Banco Central del Uruguay y la Cámara Uruguaya de *Fintech* (2023), uno de los principales beneficios de la aplicación de IA en el ámbito del *scoring* crediticio es la posibilidad de ampliar la inclusión financiera mediante modelos más precisos, dinámicos y adaptados a diferentes perfiles de riesgo.

"La incorporación de técnicas de inteligencia artificial en las soluciones *fintech* de crédito permite una mayor eficiencia en la asignación de recursos, logrando evaluar perfiles de usuarios no tradicionales, especialmente aquellos sin historial en burós de crédito" (BCU & CUF, 2023, p. 17). Esta afirmación refuerza la importancia de considerar fuentes de

datos no tradicionales y metodologías algorítmicas avanzadas para construir modelos adaptados al contexto local.

Ingeniería de Características para Scoring Alternativo

El paso siguiente a la recolección de datos es la ingeniería de variables, proceso que permite transformar información bruta en representaciones numéricas relevantes y predictivas. En los modelos tradicionales, las variables eran tratadas como atributos discretos y agrupadas en segmentos de riesgo, siguiendo un enfoque escalonado típico de los scorecards clásicos.

La introducción de scorecards líquidos (*liquid scorecards*) significó un avance metodológico importante, permitiendo representar variables continuas mediante funciones spline suaves —en particular B-splines— de segundo, tercer o cuarto orden. Estas funciones permiten que el score varíe de forma continua en función de las variables subyacentes, evitando saltos abruptos y mejorando la precisión predictiva (Hoadley, 2000).

Arquitectura de Alto Nivel del Sistema

Un sistema de *scoring* basado en IA se estructura en seis componentes funcionales, los cuales conforman una arquitectura conceptual flexible y escalable:

1. **Consumo de datos:** Se integran datos desde fuentes internas (sistemas financieros, CRM) y externas (burós, servicios públicos, plataformas digitales).
2. **Preprocesamiento:** Incluye validación, normalización, tratamiento de valores nulos y detección de anomalías.

3. **Generación de características:** Se derivan variables adicionales (por ejemplo, ratios deuda-ingreso), se aplican transformaciones matemáticas y se emplean técnicas de codificación para variables categóricas.
4. **Modelado predictivo:** Se entrena un modelo mediante técnicas de aprendizaje supervisado, pudiendo incluir desde regresiones logísticas hasta algoritmos complejos como *gradient boosting* o redes neuronales.
5. **Cálculo del score y explicabilidad:** El sistema genera un puntaje único por solicitante, acompañado de los principales factores que impactan en su valoración.
6. **Despliegue y monitoreo:** El modelo se expone mediante APIs o motores de decisión, mientras que se supervisa su desempeño y se actualiza ante eventuales desviaciones.

Flujos de Proceso y Roles Involucrados

Los sistemas de *scoring* con IA siguen un flujo estructurado que garantiza calidad, trazabilidad y gobernanza:

1. Recolección y consolidación de datos
2. Limpieza, validación y enriquecimiento de variables
3. Ingeniería de características
4. Entrenamiento y validación del modelo
5. Evaluación del desempeño (AUC, Gini, Divergence)
6. Implementación y operación en producción
7. Monitoreo continuo y reentrenamiento adaptativo

En este proceso participan diversos actores: científicos de datos, ingenieros de datos, especialistas en riesgo, áreas de producto y crédito, auditoría y cumplimiento, e ingenieros MLOps. La incorporación de principios de diversidad, equidad e inclusión (DEI) en estos procesos no solo es una exigencia ética, sino una necesidad operativa. Según AI for Good Foundation (2023), integrar prácticas pro-DEI en los sistemas algorítmicos mejora la calidad del modelo, reduce el sesgo y amplía el acceso justo al crédito en poblaciones históricamente excluidas.

Representantes del Banco Central del Uruguay (comunicación personal, 2024) expresaron su interés en el desarrollo de modelos de *scoring* basados en inteligencia artificial como herramienta de bien público. Si bien el BCU no puede legalmente asignar categorías crediticias, sí visualiza con buenos ojos la creación de un modelo generalista, explicable y transparente, orientado a empoderar al usuario financiero y fortalecer los mecanismos de supervisión. Este tipo de propuesta, en articulación con organismos como AGESIC y Equifax, podría funcionar como referencia para validar prácticas del sector privado, contribuir a la equidad en el acceso al crédito y fomentar la transparencia algorítmica en el sistema financiero nacional.

Panizza destaca que la riqueza informativa que puede extraerse del lenguaje natural abre una nueva frontera para el análisis de riesgo. A modo de ejemplo, plantea que incluso una simple solicitud en lenguaje humano, como “dame un crédito por favor”, podría contener información emocional o conductual relevante que contribuya a una evaluación más integral del cliente. En este sentido, considera que los sistemas tradicionales “calibran con análisis bastante rústicos”, mientras que los modelos actuales podrían comenzar a inferir patrones de ansiedad, urgencia o simulación reiterada, integrando variables blandas de gran valor predictivo (Panizza, comunicación personal, 2025).

4. TRANSPARENCIA, ÉTICA Y SESGOS EN SCORING CON IA

La implementación de sistemas de *scoring* crediticio basados en inteligencia artificial plantea desafíos fundamentales que trascienden las consideraciones puramente técnicas. La complejidad inherente a estos sistemas, ya se basen en modelos de regresión lineal tradicionales o en sofisticados algoritmos de *machine learning*, requiere una evaluación crítica de dos aspectos esenciales: la capacidad de explicar las decisiones algorítmicas y la selección cuidadosa de variables que garanticen tanto la precisión predictiva como el tratamiento equitativo de los solicitantes.

Ignacio Carballo (comunicación personal, 2024) advierte que, si bien la inteligencia artificial tiene fundamentos técnicos sólidos para generar valor en el sector financiero, aún se percibe un exceso de expectativas que no siempre se condicen con implementaciones efectivas. Según su experiencia, muchas empresas han adoptado soluciones de IA con fines más orientados al posicionamiento comercial que al impacto real sobre los procesos crediticios. Esta observación refuerza la necesidad de evaluar críticamente tanto el potencial como las limitaciones de la IA, particularmente en su aplicación a decisiones automatizadas sensibles como el *scoring* financiero.

Esta dualidad presenta un dilema particular en el contexto latinoamericano, donde la regulación sobre algoritmos de decisión automatizada es considerablemente más laxa que en jurisdicciones como Estados Unidos o la Unión Europea. Esta flexibilidad regulatoria permite la utilización de variables que en otros contextos podrían ser consideradas éticamente cuestionables o discriminatorias. Adicionalmente, la cultura financiera regional se caracteriza por una menor demanda de transparencia por parte de los usuarios, quienes tradicionalmente aceptan las decisiones institucionales sin solicitar explicaciones detalladas.

La convergencia de la inteligencia artificial generativa con los sistemas de *scoring* crediticio intensifica estos dilemas éticos. En una era donde los algoritmos predicen preferencias de entretenimiento, hábitos de consumo y comportamientos futuros, la aplicación de estas tecnologías a decisiones financieras fundamentales plantea interrogantes sobre la autonomía individual, el uso de datos personales y los mecanismos de acceso a servicios financieros esenciales.

Explicabilidad de Modelos (XAI)

Evolución Histórica de los Procesos de Decisión Crediticia

Históricamente, las decisiones de aprobación crediticia se fundamentaban en el juicio personal de empleados bancarios, basado en conocimiento experiencial y evaluación subjetiva del solicitante. Esta aproximación personalizada evolucionó gradualmente hacia la incorporación de modelos estadísticos de predicción, donde variables cuantificables generaban puntajes que informaban, pero no determinaban completamente, la decisión final.

La transición hacia sistemas automatizados basados en inteligencia artificial representa un cambio paradigmático fundamental. En este nuevo modelo, los algoritmos pueden adoptar criterios de aprobación o rechazo basados en patrones aprendidos de manera autónoma, reduciendo significativamente la intervención humana en el proceso decisorio. Esta automatización genera lo que se conoce como el "problema de la caja negra", donde las decisiones algorítmicas carecen de explicabilidad comprensible.

El Desafío de la Interpretabilidad

La utilidad de los sistemas de inteligencia artificial en *scoring* crediticio está intrínsecamente vinculada a su capacidad de explicación. La interpretabilidad del modelo varía en función de la cantidad de variables incorporadas y la complejidad computacional alcanzada con los datos disponibles. Contrariamente a la intuición, un mayor número de variables no necesariamente se correlaciona con resultados más precisos, pudiendo generar tanto mejoras significativas como errores sistemáticos.

El problema de la caja negra limita fundamentalmente la aplicabilidad práctica de estos sistemas, especialmente en contextos regulados donde la transparencia es un requisito legal o ético. La ausencia de explicabilidad socava la confianza tanto de usuarios como de reguladores, elementos esenciales para la viabilidad a largo plazo de cualquier sistema financiero.

Diego Vallarino y Rafael Mantero (comunicación personal, 2024) coincidieron en señalar que uno de los principales obstáculos para la adopción de modelos de *scoring* basados en inteligencia artificial es justamente la limitada interpretabilidad de sus decisiones. Mantero remarcó que existe una “tensión constante entre el poder predictivo y la capacidad explicativa”, lo que obliga a equilibrar rendimiento técnico con claridad operativa ante reguladores, inversores y usuarios. Vallarino, por su parte, advirtió que las regulaciones emergentes —inspiradas en modelos europeos— están comenzando a exigir trazabilidad completa, tanto de los datos utilizados como de los procesos de entrenamiento y validación, lo que representa un desafío técnico y organizacional para muchas instituciones financieras.

Inteligencia Artificial Explicable (XAI)

La disciplina de Inteligencia Artificial Explicable (XAI, por sus siglas en inglés) emerge como respuesta a estos desafíos, desarrollando metodologías que permiten la interpretación de decisiones algorítmicas complejas. Dos técnicas principales dominan este campo:

SHAP (SHapley Additive exPlanations): Fundamentado en la teoría de juegos cooperativos, SHAP asigna valores de contribución a cada característica en una predicción específica. Este método proporciona tanto explicaciones locales (para decisiones individuales) como explicaciones globales (para el comportamiento general del modelo).

LIME (Local Interpretable Model-agnostic Explanations): Esta técnica se centra en explicaciones locales, aproximando el comportamiento del modelo complejo mediante modelos interpretables simples (como regresiones lineales) en el entorno de una predicción específica. La Tabla 4.1 presenta una comparación sistemática de estas metodologías:

Tabla 4.1 *Comparación entre Técnicas de Explicabilidad LIME y SHAP*

Característica	LIME	SHAP
Tipo de explicación	Local (centrada en ejemplos individuales)	Local y global (agregable para explicación comprehensiva)
Modelo interpretativo	Lineal (regresión lineal o árboles simples)	Aditivo (suma de valores Shapley por característica)
Fundamento teórico	Aproximación local mediante muestreo	Teoría de valores Shapley (juegos cooperativos)

Eficiencia computacional	Relativamente rápido para pocas variables	Kernel SHAP es computacionalmente intensivo
--------------------------	---	---

Identificación y Mitigación de Sesgos

Potencial Transformador de la IA en Inclusión Financiera

A pesar de los desafíos de explicabilidad, la inteligencia artificial ofrece oportunidades significativas para expandir el acceso crediticio y reducir disparidades sistémicas. La capacidad de análisis de variables no tradicionales permite la evaluación de solicitantes que no se ajustan a patrones convencionales de riesgo crediticio.

Casos internacionales demuestran este potencial transformador. Tala utiliza datos de dispositivos móviles para evaluar solicitantes en Kenia, expandiendo el acceso crediticio en mercados con limitada infraestructura financiera tradicional. FairPlay se especializa en mitigar sesgos de género en Estados Unidos, mientras que Petal desarrolla modelos basados en flujo de efectivo que consideran patrones de ingresos no convencionales. En India, LendingKart utiliza datos alternativos para evaluar emprendedores rurales tradicionalmente excluidos del sistema financiero formal.

Identificación de Sesgos Sistémicos

La identificación de sesgos requiere un análisis crítico de las variables utilizadas y sus interrelaciones potenciales con características protegidas. Los sesgos pueden manifestarse de manera directa (uso explícito de variables discriminatorias) o indirecta (variables proxy que correlacionan con características protegidas).

Un ejemplo paradigmático es el uso de códigos postales o información de vecindario como variable predictiva. Aunque aparentemente neutral, esta información puede funcionar como proxy para características raciales o socioeconómicas, perpetuando desigualdades sistémicas bajo una apariencia de objetividad técnica.

Estrategias de Mitigación

La mitigación efectiva de sesgos requiere un enfoque multifacético que incluye:

1. **Evaluación Pre-implementación:** Análisis exhaustivo de variables para identificar correlaciones potenciales con características protegidas.
2. **Auditoría Continua:** Monitoreo sistemático del comportamiento del modelo para detectar patrones discriminatorios emergentes.
3. **Validación Cruzada:** Evaluación del rendimiento del modelo across diferentes grupos demográficos para identificar disparidades de tratamiento.
4. **Corrección Algorítmica:** Implementación de técnicas de *fairness* que ajusten las predicciones para garantizar equidad entre grupos.

Es fundamental mantener en perspectiva el propósito de la automatización crediticia: beneficiar a los consumidores finales mediante mayor acceso y tratamiento más equitativo. Cuando este objetivo se pierde, la automatización puede resultar en sistemas más eficientes, pero menos justos.

Privacidad y Protección de Datos Personales

El Ecosistema de Datos en la Era Digital

Los sistemas de *scoring* basados en IA dependen fundamentalmente de grandes volúmenes de datos personales generados continuamente a través de interacciones digitales. Esta información abarca desde datos biométricos recolectados por dispositivos como los relojes inteligentes hasta patrones de comportamiento digital registrados en transacciones electrónicas y navegación web.

La generación constante de datos estructurados y no estructurados presenta oportunidades significativas para mejorar la precisión de modelos predictivos. Sin embargo, esta riqueza informacional plantea interrogantes fundamentales sobre privacidad individual y consentimiento informado.

Consentimiento y Uso de Datos

La realidad del consentimiento digital frecuentemente se reduce a aceptaciones automáticas de términos y condiciones extensos que los usuarios raramente leen completamente. Esta práctica genera una asimetría informacional donde los usuarios ceden derechos sobre información personal sensible sin comprensión completa de las implicaciones futuras.

La distinción entre diferentes tipos de datos es crucial para una evaluación ética apropiada. El acceso a información de contacto para propósitos de marketing directo presenta riesgos significativamente menores que el acceso a historiales médicos o información financiera detallada, cuyos usos inadecuados pueden generar daños sustanciales.

Marco Regulatorio Global

La regulación internacional ha evolucionado significativamente para abordar estos desafíos. El Reglamento General de Protección de Datos (GDPR) de la Unión Europea establece estándares estrictos para el procesamiento de datos personales, incluyendo el derecho al olvido y la portabilidad de datos. Estados Unidos ha desarrollado regulaciones sectoriales específicas, mientras que países latinoamericanos han implementado marcos normativos con diferentes grados de rigor.

Cumplimiento Normativo y Regulatorio en Uruguay

Marco Constitucional

La protección de datos personales constituye un derecho humano fundamental en Uruguay, reconocido explícitamente en el artículo 72 de la Constitución Nacional. Este reconocimiento constitucional proporciona una base sólida para el desarrollo de marcos regulatorios específicos.

Ley 18.331 de Protección de Datos Personales

En 2008, Uruguay promulgó la Ley 18.331, estableciendo un marco para la protección de datos personales y creando la Unidad Reguladora y de Control de Datos Personales (URCDP) como autoridad de aplicación. Esta legislación establece los siguientes principios fundamentales:

Derechos de los Titulares: La legislación reconoce derechos fundamentales incluyendo acceso, rectificación, actualización y supresión de datos personales. Adicionalmente, los titulares pueden impugnar decisiones automatizadas que afecten jurídicamente sus derechos.

Regulación del Tratamiento: La normativa establece requisitos específicos para el tratamiento lícito de datos, incluyendo principios de autorización, información a titulares, seguridad en el procesamiento y transparencia en las operaciones.

Régimen Sancionatorio: La legislación contempla sanciones administrativas graduadas para infracciones a las normas de protección de datos, proporcionando incentivos para el cumplimiento efectivo.

Transferencias Internacionales: La normativa regula las transferencias transfronterizas de datos, requiriendo niveles adecuados de protección en países de destino o implementación de salvaguardas apropiadas.

Excepciones Específicas: La ley contempla excepciones limitadas para actividades de seguridad pública, investigación criminal y otras funciones gubernamentales esenciales, manteniendo un equilibrio entre protección individual e intereses públicos legítimos.

Implicaciones para Sistemas de Scoring con IA

La implementación de sistemas de *scoring* basados en IA en Uruguay debe considerar estos requisitos regulatorios desde la fase de diseño. Esto incluye la implementación de mecanismos de explicabilidad que permitan a los titulares comprender las decisiones automatizadas, procedimientos de rectificación de datos inexactos, y salvaguardas técnicas y organizacionales para garantizar la seguridad de la información procesada.

Patricia Dopazo (comunicación personal, 2024) señala que la limitada presión del mercado por innovar, junto con un regulador conservador, actúa como freno a la adopción de tecnologías disruptivas como la inteligencia artificial en el sistema financiero uruguayo. Esta situación condiciona no solo la implementación técnica, sino también el desarrollo normativo necesario para su integración ética y segura.

El cumplimiento efectivo requiere un enfoque proactivo que integre consideraciones de privacidad y protección de datos en todas las fases del ciclo de vida del sistema, desde la recolección inicial de datos hasta la implementación de decisiones automatizadas y la eventual eliminación de información personal.

HALLAZGOS Y DESAFÍOS

Finanzas Abiertas, Datos Alternativos, Educación e Inteligencia Artificial para el *scoring crediticio*.

El avance acelerado de la inteligencia artificial abarca múltiples sectores, incluyendo el sistema financiero, donde su adopción ha progresado más rápidamente en aplicaciones como asistentes virtuales y *chatbots* que en procesos críticos de toma de decisiones. La implementación de IA en estos procesos decisionales, aunque altamente prometedora, requiere un tratamiento cuidadoso y sensible que conlleva tiempos de desarrollo e implementación más prolongados. Esta necesidad de cautela contrasta con el ritmo vertiginoso de evolución de los modelos de inteligencia artificial, generando una tensión entre la velocidad de innovación tecnológica y los requerimientos de seguridad y confiabilidad que demandan los procesos financieros críticos. Este desafío se manifiesta particularmente en América Latina y, específicamente, en Uruguay.

A pesar de no contar aún con una estrategia nacional específica sobre inteligencia artificial, Uruguay presenta condiciones institucionales y regulatorias más estables que muchos países de la región. Esta estabilidad brinda una base favorable para avanzar hacia marcos normativos más estructurados y sostenibles.

En comparación con otras jurisdicciones, Uruguay se destaca por su cultura de respeto a los derechos fundamentales, especialmente en lo que refiere a la protección de datos personales, donde ya cuenta con legislación avanzada y una autoridad especializada (URCDP). Esto le otorga una posición ventajosa a la hora de desarrollar sistemas de IA que respeten principios éticos y regulatorios.

Asimismo, aunque aún fragmentada, la articulación interinstitucional entre actores como AGESIC, la URCDP y el Banco Central del Uruguay, demuestra un ecosistema con

potencial de coordinación. En otros países analizados, (Argentina, Brasil, Chile) esa coordinación entre innovación tecnológica y regulación es mucho más débil o inexistente.

Finalmente, Uruguay posee un entorno democrático consolidado, con altos niveles de digitalización en la administración pública y confianza institucional, lo cual representa una ventaja estructural para la adopción responsable de inteligencia artificial, particularmente en sectores sensibles como el financiero.

Este contexto presenta una oportunidad estratégica para liderar no solo en la adopción de tecnologías emergentes, sino también en la integración de estas temáticas en la formación académica. La incorporación de contenidos sobre inteligencia artificial, industria financiera tecnológica (*Fintech*) en los programas educativos permitiría formar profesionales con una perspectiva más amplia y competencias actualizadas, mejor preparados para enfrentar los desafíos del mercado laboral contemporáneo y para tomar decisiones informadas en sus futuros ámbitos de desempeño. La materialización de estos beneficios potenciales requiere, sin embargo, de decisiones concretas y acciones deliberadas por parte de las instituciones educativas y los responsables de política nacional.

Finanzas Abiertas, Datos Alternativos

En el marco de los esfuerzos globales por modernizar los sistemas financieros, el concepto de *Finanzas Abiertas* (Open Finance) se presenta como una evolución del modelo de *Banca Abierta* (Open Banking), extendiendo el intercambio seguro y consentido de datos desde cuentas bancarias hacia un espectro más amplio de productos financieros, incluyendo seguros, inversiones, pensiones y ahorro. Este paradigma promueve la interoperabilidad entre actores del ecosistema, mejora la competitividad del

mercado y abre nuevas oportunidades para el desarrollo de soluciones basadas en inteligencia artificial.

En Uruguay, el Banco Central había delineado una hoja de ruta hacia el año 2025 para el desarrollo de un ecosistema de Finanzas Abiertas, el cual se basa en principios como el consentimiento informado, la estandarización técnica de interfaces, y la gobernanza participativa (Banco Central del Uruguay, 2023). Esta iniciativa reconoce la necesidad de habilitar modelos de negocio basados en el uso inteligente de los datos y establece las condiciones habilitantes para una innovación financiera responsable y competitiva.

Desde una perspectiva tecnológica, la apertura de datos financieros mediante APIs permite el acceso a información granular y reciente del comportamiento transaccional de los usuarios. Este tipo de datos representa una fuente altamente valiosa para la construcción de modelos de *scoring* crediticio más precisos, especialmente en escenarios donde se evalúa a clientes sin historial crediticio tradicional. Estudios recientes como el de Hjelkrem et al. (2022) han demostrado que modelos de aprendizaje profundo basados exclusivamente en datos transaccionales de los últimos 90 días, obtenidos a través de interfaces de *Open Banking*, pueden superar en capacidad predictiva a los modelos convencionales para clientes nuevos. Además, la combinación de estos datos con atributos estructurados mediante modelos ensamble permite reducir sustancialmente la brecha de precisión entre *scoring* para nuevos y antiguos clientes, mejorando la eficiencia del sistema crediticio.

Complementariamente, investigaciones como la de Hlongwane y Nyaholisa (2024) resaltan el valor de los datos alternativos —tales como historial de pagos de servicios, actividad digital o redes sociales— en la construcción de modelos de riesgo más inclusivos. Estos datos, en combinación con técnicas avanzadas de IA, permiten inferir

patrones de comportamiento crediticio no captados por las fuentes tradicionales, abriendo la puerta a la bancarización de sectores históricamente excluidos del sistema financiero formal.

El despliegue efectivo de este nuevo paradigma exige marcos normativos modernos que, más allá de regular tecnologías, aborden actividades y riesgos asociados. La literatura especializada recomienda regulaciones basadas en funciones económicas, promoviendo la neutralidad tecnológica y permitiendo el ingreso simétrico de nuevos actores al mercado. Ejemplos internacionales como la Directiva PSD2 en Europa, el sistema de pagos instantáneos PIX en Brasil, o el esquema de consentimiento activo en Australia, muestran cómo un enfoque regulatorio equilibrado puede habilitar modelos de innovación con protección efectiva de los datos personales.

En este escenario, Uruguay posee una oportunidad estratégica para consolidarse como hub regional de innovación financiera. El fortalecimiento del marco institucional, la implementación de *sandboxes* regulatorios, o entornos de prueba para la estandarización de protocolos de intercambio de datos y el desarrollo de infraestructura crítica —como una Cámara de Compensación Automatizada de carácter público— son elementos clave para sustentar una transformación sostenible y alineada con principios de transparencia, inclusión y eficiencia.

En suma, las iniciativas de *Open Banking* y *Open Finance* no sólo habilitan nuevas dinámicas competitivas, sino que se presentan como catalizadores esenciales para la modernización del sistema de evaluación crediticia. La integración de datos abiertos, datos alternativos e inteligencia artificial no constituye una promesa futura, sino una realidad que ya está transformando la manera en que las instituciones financieras

identifican, evalúan y mitigan el riesgo, y en la que Uruguay está llamado a participar activamente.

CONCLUSIONES

“La tecnología no es buena ni mala, pero su futuro depende de las decisiones que tomemos hoy. Podemos usarla para construir sociedades más justas o para reforzar las desigualdades.”

— Harari, Y. N. (2016). *Homo Deus: Breve historia del mañana*.

La hipótesis inicial de esta investigación planteaba que el estado del arte en el uso de inteligencia artificial para *scoring* crediticio constituía un campo consolidado con amplia adopción en diversas áreas del sector financiero. Esta premisa se fundamentaba en la prominencia mediática del tema y la frecuente discusión en foros especializados, lo que motivó a los investigadores a seleccionar esta temática para su abordaje académico.

Sin embargo, durante las primeras etapas del desarrollo investigativo, las entrevistas realizadas a diferentes actores del mercado revelaron una realidad considerablemente más austera que el discurso inicial. Se evidenció una brecha significativa entre las declaraciones de intención ("estamos trabajando en ello") y la implementación práctica de soluciones realmente aplicables en el contexto del *scoring* crediticio.

A lo largo del proceso investigativo surgieron diversos casos de uso de IA en el sector financiero, aunque la mayoría se encontraba fuera del alcance específico de este estudio. Esta situación reflejó la dificultad inherente para acceder a información detallada sobre implementaciones concretas, las cuales suelen permanecer en el ámbito de los titulares sin mayor profundización en sus aspectos técnicos y operativos.

No obstante, el estudio reforzó la convicción sobre la necesidad de abordar esta temática de manera rigurosa, particularmente en relación con su potencial impacto en la inclusión financiera. Si bien es cierto que las prácticas para aumentar la inclusión financiera han

sido implementadas desde la década de los setenta iniciando con microcréditos en India donde años después se extrapolaría esa lógica de negocio especialmente a Colombia y a Perú. El cambio de paradigma tecnológico actual aporta nuevas variables de evaluación, metodologías de seguimiento más sofisticadas y mayor capacidad de inclusión, permitiendo así abarcar poblaciones más amplias, que no sólo rentabilizan un negocio, sino que impulsan el crecimiento económico orgánico de poblaciones menos favorecidas por la industria tradicional, aportando al crecimiento de un país.

Esta transformación no se limita únicamente a aspectos de inclusión financiera, sino que resuena con la perspectiva expresada por Patricia Dopazo en las entrevistas iniciales: "lo que son créditos, consumo y servicios, tarjeta de crédito y demás, eso es todo tecnología, y el que lo haga mejor va a ser el ganador en los próximos 10 años".

Aunque muchos de los desarrollos observados en la región aún están en etapas preliminares, uno de los entrevistados sostiene que en los próximos años será común ver motores de decisión basados en IA integrados directamente al core bancario. En su experiencia, ya se están desarrollando interfaces conversacionales en las que el usuario simplemente habla o escribe, el sistema interpreta la intención y ejecuta los servicios bancarios necesarios. Este paradigma implicaría el reemplazo de formularios por asistentes inteligentes, lo que representa un salto tecnológico y cultural profundo en la experiencia financiera (Panizza, comunicación personal, 2025).

El proceso de aprendizaje evidenció la necesidad imperativa de que la academia desarrolle marcos conceptuales más robustos para comprender el funcionamiento de las instituciones financieras y sus metodologías de evaluación crediticia. Esta comprensión resulta fundamental para generar conocimiento aplicable que pueda traducirse en mejores prácticas del sector.

Por lo que respondiendo a las preguntas que se han planteado inicialmente podemos decir que el mercado financiero uruguayo presenta una estructura consolidada, dominada por entidades bancarias tradicionales con fuerte regulación institucional, complementadas por un ecosistema fintech en crecimiento. A pesar de contar con marcos normativos robustos en materia de protección de datos y supervisión financiera, el país aún no ha desarrollado una estrategia nacional específica en inteligencia artificial ni en finanzas abiertas. En cuanto a las prácticas actuales de evaluación crediticia, prevalecen los modelos convencionales sustentados en datos históricos, reglas fijas y referencias provenientes de registros financieros formales, lo cual limita su capacidad para incorporar a segmentos desatendidos y no bancarizados.

Dentro de este contexto, las herramientas de inteligencia artificial ofrecen una oportunidad para evolucionar los modelos de *scoring* financiero hacia esquemas más dinámicos y precisos. Algoritmos de *machine learning*, como los árboles de decisión, redes neuronales o modelos de clasificación supervisados, permiten detectar patrones complejos en grandes volúmenes de datos. Asimismo, técnicas como el procesamiento de lenguaje natural o los sistemas conversacionales amplían las fuentes de información disponibles, captando señales conductuales y emocionales que podrían mejorar la evaluación de riesgo. Estas capacidades técnicas, si bien aún poco utilizadas en Uruguay, representan una alternativa real para superar las limitaciones de los métodos tradicionales.

Para diseñar un modelo de *scoring* crediticio basado en IA que garantice efectividad predictiva, transparencia y principios éticos, resulta clave aplicar enfoques metodológicos integrales. Esto implica seleccionar algoritmos explicables, establecer criterios inclusivos en la elección de variables, e incorporar mecanismos de trazabilidad y auditoría algorítmica. La transparencia no solo fortalece la confianza del cliente en las decisiones tomadas, sino que también facilita el cumplimiento regulatorio y la adaptación

tecnológica por parte de las instituciones. Además, un diseño responsable puede promover la equidad y mitigar los sesgos algorítmicos, contribuyendo así a una relación más sólida y sostenible entre las entidades financieras y sus usuarios.

La inteligencia artificial tiene el potencial de transformar los sistemas de evaluación crediticia en Uruguay al permitir modelos más flexibles, precisos y centrados en el usuario. Su aplicación puede ampliar el acceso al crédito, incorporar a poblaciones tradicionalmente excluidas y optimizar los procesos internos de las instituciones financieras. A través del uso ético y transparente de datos y algoritmos, es posible construir herramientas que no sólo predigan con mayor exactitud el riesgo, sino que lo hagan respetando principios de equidad, inclusión y trazabilidad, contribuyendo al fortalecimiento del sistema financiero uruguayo en su conjunto.

Implicaciones y Recomendaciones

Los hallazgos de esta investigación sugieren varias áreas de oportunidad para el desarrollo futuro:

Enfoque en inclusión financiera: Los resultados indican la necesidad de desarrollar marcos regulatorios que promuevan la inclusión financiera a través del uso responsable de tecnologías de IA, garantizando que estas herramientas amplíen el acceso al crédito sin comprometer la estabilidad del sistema financiero.

Apertura regulatoria: Las restricciones encontradas en el trabajo con el Banco Central del Uruguay (BCU) destacan la importancia de generar cambios regulatorios que promuevan la innovación tecnológica y faciliten la adopción de nuevas metodologías de evaluación crediticia.

Transformación hacia finanzas abiertas: La investigación evidencia una oportunidad para que Uruguay encuentre beneficios avanzando hacia un modelo de finanzas abiertas que privilegie la gobernanza centrada en el usuario, especialmente considerando la complejidad creciente del ecosistema financiero global y la necesidad del país de atraer inversiones en el sector tecnológico-financiero como sandbox o banco de prueba regional de servicios tecnológicos y financieros, así como la posibilidad de ofrecer a los usuarios del sistema más y mejores servicios.

En conclusión, aunque la implementación práctica de IA en *scoring* crediticio presenta desafíos significativos en términos de adopción y transparencia, el potencial transformador de estas tecnologías justifica la continuidad de la investigación académica en esta área, particularmente en el contexto uruguayo donde existe una oportunidad única para desarrollar marcos innovadores que combinen eficiencia tecnológica con inclusión financiera.

Cómo dice Harari, “la *tecnología no es buena ni mala*”, por lo que esta en nuestras manos decidir el rol que va a jugar en el día a día, en las políticas públicas, en la educación. Lo que si queda claro es que no es tiempo de esperar, el nuevo paradigma ya está acá y adaptarse será la condición imprescindible para avanzar.

Referencias

- AI for Good Foundation. (2023). *Artificial intelligence for financial inclusion: A framework for responsible AI in credit scoring*. AI for Good Foundation.
- Alonso-Robisco, A., & Carbo, J. M. (mayo de 2023). Aprendizaje automático en modelos de concesión de crédito: oportunidades y riesgos. En A. AlonsoRobisco, & J. M. Carbo, Analisis financiero y big data (págs. 79-104). FUNCAS. FUNCAS: <https://www.funcas.es/articulos/aprendizaje-automaticoen-modelos-de-concesion-de-credito-oportunidades-y-riesgos/>
- Andrews, E. L. (6 de Agosto de 2021). HAI, Stanford University. <https://hai.stanford.edu/news/how-flawed-data-aggravates-inequality-credit>
- Arner, D. W., Zetsche, D. A., Buckley, R. P., & Barberis, J. N. (2021). *Open finance, financial ecosystems and the future of banking*. Georgetown Journal of International Law, 52, 113–159.
- Banco Central do Brasil. (2023). *Open Finance: Relatório de Acompanhamento*. Recuperado de <https://www.bcb.gov.br>
- Banco Central do Brasil. (2024). *Estatísticas Pix*. Recuperado de <https://www.bcb.gov.br>
- Banco Central del Uruguay. (2023). *Hacia un ecosistema de Finanzas Abiertas en Uruguay*. Montevideo: BCU. Recuperado de <http://www.bcu.gub.uy/Sistema-de-Pagos/Documents/Sistema%20de%20Pagos-hoja-de-ruta-2025.pdf>
- Banco Central del Uruguay & Cámara Uruguaya de Fintech. (2023). *Informe sobre el ecosistema fintech uruguayo 2023*. BCU.
- Barocas, S., Hardt, M., & Narayanan, A. (2019). *Fairness and machine learning: Limitations and opportunities*. MIT Press.

- Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the dangers of stochastic parrots: Can language models be too big? *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency*, 610-623.
- CGAP. (2021). *Designing public digital infrastructure for an inclusive future*. Consultative Group to Assist the Poor (World Bank). Recuperado de <https://www.cgap.org/research/publication/designing-public-digital-infrastructure-inclusive-future>
- Chainalysis. (2023). *The 2023 Global Crypto Adoption Index*. Recuperado de <https://www.chainalysis.com>
- Dassatti, C. (2023). *Scoring crediticio en empresas administradoras de crédito en Uruguay* [Documento de trabajo]. Banco Central del Uruguay.
- Deloitte. (2024). How Artificial Intelligence is Transforming the Financial Services Industry. Deloitte: <https://www.deloitte.com/ng/en/services/riskadvisory/services/how-artificial-intelligence-is-transforming-the-financialservices-industry.html>
- Durand, D. (1941). Risk elements in consumer instalment financing. *Technical Papers of the National Bureau of Economic Research*, 8.
- Fair Isaac Corporation. (2017). *The evolution of credit scoring: From traditional models to AI-powered solutions*. FICO.
- Gamboa, D. A., Parra-Sánchez, J., Arias, B., & Garcia, C. (2024). *Modelo de decisión basado en IA para otorgamiento de crédito en Servicrédito S.A.* En V. García Pineda (Ed.), *Actas del V Congreso Internacional en Administración de Negocios Internacionales – CIANI 2024* (pp. 267–274). Universidad Cooperativa de Colombia. <https://www.researchgate.net/publication/385312043>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Harari, Y. N. (2016). *Homo Deus: Breve historia del mañana*. Debate.
- Hernández Sampieri, R., Fernández Collado, C., & Baptista, P. (2014). *Metodología de la investigación* (6.ª ed.). McGraw-Hill.
- Hidayat, M., Defitri, S. Y., & Hilman, H. (30 de Enero de 2024). The Impact of Artificial Intelligence(AI) on Financial Management. *Management Studies and Business Journal*, 1(1), 123-129. <https://doi.org/https://doi.org/10.62207/s298rx18>
- Hjelkrem, L. O., de Lange, P. E., & Nettet, E. (2022). The value of open banking data for application credit scoring: Case study of a Norwegian bank. *Journal of Risk and Financial Management*, 15(12), 597. <https://doi.org/10.3390/jrfm15120597>

- Hlongwane, R., & Nyaholisa, T. (2024). Enhancing credit scoring accuracy with a comprehensive evaluation of alternative data. *South African Journal of Economic and Management Sciences*, 27(1). <https://doi.org/10.4102/sajems.v27i1.5146>
- Hoadley, B. (2000). *Liquid scorecards: Continuous scoring with spline functions*. Fair Isaac Corporation.
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression* (3rd ed.). Wiley.
- Jain, R. (2023). Artificial intelligence in Latin American financial services: Opportunities and challenges. *Journal of Financial Technology*, 15(3), 45-62.
- Jakka, G., Panigrahi, A., Pati, A., & Tripathy, M. N. (2023). A novel credit scoring system in financial institutions using artificial. *Journal of Autonomous Intelligence* (2023) Volume 6 Issue 2. <https://doi.org/https://doi.org/10.32629/jai.v6i2.824>
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An introduction to statistical learning: With applications in R* (2nd ed.). Springer.
- Johnson, R. A., & Wichern, D. W. (2019). *Applied multivariate statistical analysis* (6th ed.). Pearson.
- Jurafsky, D., & Martin, J. H. (2023). *Speech and language processing: An introduction to natural language processing, computational linguistics, and speech recognition* (3rd ed.). Pearson.
- M. Pandey, I. S. (2022). Artificial Intelligence Impact Evaluation: Transforming Paradigms in Financial Institutions. *World of Economics and Management*. <https://doi.org/https://doi.org/10.25205/2542-0429-2022-22-1-147-164>
- Martínez Fernández, L. (2023). Comparative analysis of machine learning algorithms for credit scoring in emerging markets. *International Journal of Financial Engineering*, 10(2), 123-145.
- Ministerio de Hacienda de Chile. (2023). *Ley para el Desarrollo del Mercado de Innovación Financiera*. <https://www.hacienda.cl/>
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115-133.
- Miller, T. (2019). Explanation in artificial intelligence: Insights from the social sciences. *Artificial Intelligence*, 267, 1-38.
- Nubank.(s.f.). <https://blog.nubank.com.br/como-utiliza-nubank-inteligencia-artificial/>
- Nuka, T. F., & Osedahunsi, B. O. (2024). From bias to balance: Integrating DEI in AI-driven financial systems to promote credit equity. *International Journal of Science and Research Archive*, 13(02), 1189–1206. <https://doi.org/10.30574/ijrsra.2024.13.2.2257>

- OECD. (2020). *Open banking: Regulatory frameworks, participant roles and overarching issues*. Organisation for Economic Co-operation and Development. <https://www.oecd.org/finance/Open-Banking.pdf>
- RadioFormula.MX. (13 de Julio de 2023). <https://www.radioformula.com.mx/estilo-devida/2023/7/13/kueski-asi-usa-la-inteligencia-artificial-para-dar-mas-creditos771199.html>
- Reepu. (2019). Artificial Intelligence in Finance and Accounting. International Journal of Innovative Technology and Exploring Engineering. <https://doi.org/https://doi.org/10.35940/ijitee.I1203.10812s19>
- Russell, S. J., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Zetsche, D. A., Arner, D. W., & Buckley, R. P. (2022). *Open banking, data and innovation in finance*. Journal of Financial Regulation and Compliance, 30(1), 9–26.
- Zetsche, D. A., Buckley, R. P., Arner, D. W., & Barberis, J. N. (2017). Regulating a revolution: From regulatory sandboxes to smart regulation. *Fordham Journal of Corporate & Financial Law*, 23(1), 31–103.