

**MODELO DE MADUREZ PARA ADOPCIÓN DE MACHINE LEARNING EN
EMPRESAS DEL SECTOR FINANCIERO COLOMBIANAS**

NICOLÁS ALFONSO ARCINIEGAS BETANCOURT

**Proyecto integral de grado para optar el título de Especialista en Machine
Learning**

UNIVERSIDAD EAN

FACULTAD DE INGENIERIA

ESPECIALIZACIÓN EN MACHINE LEARNING

BOGOTÁ, D. C.

2025

TABLA DE CONTENIDO

RESUMEN	2
ABSTRACT	3
1. PROBLEMA DE INVESTIGACIÓN	5
2. OBJETIVOS	7
3. JUSTIFICACIÓN	8
4. MARCO TEÓRICO	9
5. Metodología	21
6. Modelo de madurez para la adopción de Machine Learning	26
7. Conclusiones	40
REFERENCIAS	42
ANEXOS	45

RESUMEN

El avance de la inteligencia artificial y el machine learning (ML) ha generado altas expectativas en el sector financiero, particularmente en áreas como gestión del riesgo, detección de fraude, automatización de procesos y soporte a la toma de decisiones. No obstante, diversos estudios evidencian que, pese al interés estratégico por estas tecnologías, muchas organizaciones no logran implementar capacidades de ML de manera operativa, escalable y sostenible. En el contexto colombiano, el sector financiero presenta avances significativos en transformación digital; sin embargo, persisten brechas

relacionadas con talento especializado, gobernanza de datos, infraestructura tecnológica y cultura organizacional, lo que limita la madurez en la adopción de ML.

El presente estudio tiene como objetivo diseñar un modelo de maduración que permita evaluar el nivel de adopción de machine learning en empresas del sector financiero colombiano e identificar lineamientos para su evolución hacia un uso estratégico. La investigación se desarrolla bajo un enfoque cualitativo y descriptivo, apoyado en la revisión de literatura académica, informes institucionales y estudios sectoriales relacionados con adopción de inteligencia artificial y modelos de madurez organizacional. A partir de este análisis, se identifican dimensiones clave para la adopción de ML —estrategia, datos, tecnología, talento y cultura— y se proponen niveles progresivos de madurez que orientan el tránsito desde usos exploratorios hasta implementaciones integradas al negocio.

Como resultado, se presenta un modelo de madurez conceptual que permite diagnosticar el estado actual de las organizaciones financieras frente al uso de ML y apoyar la planificación de iniciativas futuras. Este modelo busca servir como una herramienta de referencia para entidades financieras interesadas en estructurar y fortalecer sus capacidades de machine learning, contribuyendo a una adopción más efectiva y alineada con los objetivos estratégicos del sector.

ABSTRACT

The rapid advancement of artificial intelligence and machine learning (ML) has generated high expectations within the financial sector, particularly in areas such as risk management, fraud detection, process automation, and decision support. However,

existing studies indicate that, despite strong strategic interest in these technologies, many organizations struggle to implement ML capabilities in an operational, scalable, and sustainable manner. In the Colombian context, the financial sector has made significant progress in digital transformation; nevertheless, persistent gaps remain in specialized talent, data governance, technological infrastructure, and organizational culture, limiting the maturity of ML adoption.

The objective of this study is to design a maturity model that enables the assessment of the level of machine learning adoption in Colombian financial sector organizations and provides guidelines for their evolution toward strategic use. The research follows a qualitative and descriptive approach, supported by a review of academic literature, institutional reports, and sector-specific studies related to artificial intelligence adoption and organizational maturity models. Based on this analysis, key dimensions for ML adoption—strategy, data, technology, talent, and culture—are identified, and progressive maturity levels are proposed to guide organizations from exploratory initiatives to business-integrated implementations.

As a result, this study presents a conceptual maturity model that allows financial organizations to diagnose their current state regarding machine learning adoption and to support the planning of future initiatives. The proposed model aims to serve as a reference framework for financial institutions seeking to structure and strengthen their machine learning capabilities, contributing to a more effective and strategically aligned adoption within the sector.

1. PROBLEMA DE INVESTIGACIÓN

Descripción del problema.

Durante la última década, el sector financiero ha consolidado la inteligencia artificial (IA) y el machine learning (ML) como tecnologías clave para mejorar la eficiencia operativa, gestionar riesgos, automatizar procesos y fortalecer decisiones estratégicas. No obstante, la evidencia muestra que, aunque existe interés en adoptar ML, la mayoría de organizaciones aún no logra implementar capacidades maduras.

McKinsey & Company (2018) señala que, pese al incremento global en adopción de IA, pocas empresas han desarrollado los elementos estructurales que permiten capturar valor de forma escalable, evidenciando limitaciones en datos, infraestructura, talento especializado y procesos de integración.

De manera similar, Deloitte (2023) identifica que muchas organizaciones se encuentran atrapadas en proyectos piloto o implementaciones parciales, reportando que las compañías enfrentan dificultades para mover pilotos de IA a producción debido a capacidades de datos, gobernanza y soporte operacional insuficiente.

A nivel latinoamericano, el Banco Interamericano de Desarrollo evidencia que, aunque existe creciente interés por la IA, persisten brechas de gobernanza, talento y capacidades institucionales que dificultan pasar de la experimentación inicial a despliegues sostenidos en las organizaciones (Gómez Mont et al., 2020).

Complementando esta visión, la Comisión Económica para América Latina y el Caribe (Jordan & Poveda, 2025) muestra que la región es consumidora activa de

soluciones de IA, pero su participación es limitada en el desarrollo, integración y producción de modelos, reflejando cuellos de botella en talento, infraestructura y ecosistemas de innovación.

En el contexto colombiano, el sector financiero ha avanzado en transformación digital, disponibilidad de servicios electrónicos y uso de canales digitales. Sin embargo, documentos sectoriales indican que la adopción de soluciones avanzadas de analítica e IA requiere fortalecer capacidades humanas, prácticas de gobernanza de datos y cultura organizacional para soportar proyectos de ML escalables (Asobancaria, 2021).

Esto sugiere que las entidades financieras colombianas experimentan una brecha entre la intención estratégica de usar ML y su implementación efectiva. La ausencia de un referente metodológico que permita diagnosticar el nivel de adopción y orientar la progresión organizacional dificulta planear inversiones, priorizar iniciativas y estructurar capacidades.

Por lo anterior, surge la oportunidad de diseñar un modelo de madurez para la adopción de Machine Learning en el sector financiero colombiano, que permita identificar brechas, orientar decisiones y apoyar la evolución desde usos exploratorios hacia implementaciones operativas y sostenibles.

Pregunta de investigación.

¿Qué modelo de maduración permite diagnosticar el nivel de adopción de Machine Learning en empresas del sector financiero colombiano y orientar su evolución hacia un uso estratégico y sostenible?

2. OBJETIVOS

OBJETIVO GENERAL

Diseñar un modelo de maduración que permita evaluar el nivel de adopción de Machine Learning en empresas del sector financiero colombiano e identificar lineamientos para su evolución hacia un uso estratégico.

OBJETIVOS ESPECÍFICOS

- Analizar los modelos de madurez existentes en la literatura internacional relacionados con analítica avanzada e inteligencia artificial, identificando sus componentes estructurales y factores críticos de adopción.
- Identificar barreras, capacidades organizacionales y factores habilitadores para la implementación de Machine Learning en empresas del sector financiero colombiano, desde una perspectiva documental y sectorial.
- Proponer un modelo de maduración compuesto por niveles, dimensiones y lineamientos de evolución, adaptado al contexto del sector financiero colombiano.
- Validar conceptualmente el modelo propuesto mediante revisión de literatura, contraste teórico o consulta con expertos, para determinar su pertinencia, coherencia y aplicabilidad organizacional.

3. JUSTIFICACIÓN

El presente estudio se justifica, en primer lugar, por su conveniencia, dado que el machine learning se ha consolidado como una de las principales tecnologías habilitadoras de la transformación digital en el sector financiero. En el contexto colombiano, bancos y fintech han avanzado de manera significativa en digitalización de servicios; sin embargo, persisten dificultades para adoptar el machine learning de forma estructurada y estratégica. Diseñar un modelo de madurez permite responder a esta necesidad, ofreciendo un marco que facilite la comprensión y gestión progresiva de la adopción de estas tecnologías.

Desde la perspectiva de la relevancia social, el sector financiero cumple un rol fundamental en la economía y en la inclusión financiera. Una adopción más madura y responsable del machine learning puede contribuir a mejorar la eficiencia, la transparencia y la calidad de los servicios financieros, así como a fortalecer procesos de gestión del riesgo, prevención del fraude y toma de decisiones. En este sentido, el estudio aporta indirectamente al desarrollo económico y a la modernización institucional del país, alineándose con los principios de sostenibilidad e innovación promovidos por la Universidad EAN.

En cuanto a las implicaciones prácticas, el modelo de madurez propuesto constituye una herramienta útil para las organizaciones financieras, ya que les permite diagnosticar su nivel actual de adopción de machine learning, identificar brechas organizacionales y priorizar acciones de mejora. Esto facilita la toma de decisiones estratégicas relacionadas con inversión en talento, infraestructura, gobernanza de datos

y gestión del cambio, reduciendo el riesgo de iniciativas fragmentadas o pilotos sin impacto real.

El estudio también presenta un valor teórico, al integrar conceptos de adopción tecnológica, analítica avanzada y modelos de madurez organizacional en el contexto específico del machine learning. Al adaptar estos enfoques al sector financiero colombiano, la investigación contribuye a ampliar el cuerpo de conocimiento existente, ofreciendo un marco conceptual que puede servir de referencia para estudios futuros en contextos similares o en otros sectores económicos.

Finalmente, la utilidad metodológica del estudio radica en la propuesta de un enfoque cualitativo y descriptivo para el diseño y validación conceptual de modelos de madurez. La metodología empleada puede ser replicada o ajustada en investigaciones posteriores, fortaleciendo la línea de investigación en transformación digital y analítica de datos.

En conjunto, este trabajo se enmarca en el campo de la transformación digital y la analítica aplicada, alineándose con las líneas de investigación institucionales de la Universidad EAN, especialmente aquellas orientadas a innovación, sostenibilidad y uso estratégico de tecnologías emergentes en las organizaciones.

4. MARCO TEÓRICO

4.1. Introducción al marco teórico

El machine learning (ML) se ha convertido en una de las principales capacidades tecnológicas para la transformación digital de las organizaciones, particularmente en sectores intensivos en datos como el financiero. No obstante, la literatura reciente

evidencia que la adopción de ML no depende únicamente de la disponibilidad tecnológica, sino de un conjunto de factores estratégicos, organizacionales y culturales que determinan su uso efectivo y sostenible. En este sentido, el presente marco teórico fundamenta el estudio desde teorías de adopción tecnológica, modelos de madurez organizacional y enfoques contemporáneos sobre la implementación de inteligencia artificial (IA) en empresas, con énfasis en el sector financiero.

4.2. Estado del arte sobre adopción de Machine Learning e Inteligencia Artificial (2020-2025)

Estudios recientes coinciden en que existe una brecha significativa entre el interés organizacional por la IA y la capacidad real de las empresas para escalar soluciones de ML. Ransbotham et al. (2020) evidencian que, aunque la mayoría de las organizaciones reconoce el valor estratégico de la IA, solo una minoría logra integrarla de forma sistemática en procesos críticos del negocio. Esta brecha ha sido asociada a factores como la falta de gobernanza de datos, limitaciones en talento especializado y ausencia de una estrategia clara de adopción.

Desde una perspectiva académica, Rai et al. (2021), en un estudio indexado en MIS Quarterly, señalan que la adopción de IA debe entenderse como una transformación organizacional más que como una simple implementación tecnológica. Los autores destacan que la creación de valor a partir del ML requiere rediseñar procesos, estructuras y mecanismos de toma de decisiones.

En el contexto latinoamericano, el Banco Interamericano de Desarrollo (BID, 2021) documenta que la región enfrenta rezagos en capacidades institucionales para la

adopción de IA, particularmente en sectores regulados como el financiero. La CEPAL (2025) complementa estos hallazgos al indicar que América Latina presenta un patrón de alto consumo de soluciones de IA, pero una baja participación en el desarrollo, entrenamiento e integración de modelos, lo cual refleja niveles de madurez tecnológica incompletos. Esto se puede evidenciar al revisar observar la Figura 1, en donde se evidencia que la ética a nivel de Latinoamérica se ha desarrollado, pero los demás factores que rodean la adopción de IA se ven muy por debajo de los países seleccionados de la OCDE.




Figura 1. América Latina y el Caribe (9 países), y Organización de Cooperación y Desarrollo Económicos (OCDE) (7 países): grado de intensidad temática relativa en las políticas y estrategias digitales, (CEPAL, 2022)

Investigaciones recientes enfatizan la necesidad de marcos de referencia que orienten la adopción progresiva de la inteligencia artificial. En este sentido, la Organización para la Cooperación y el Desarrollo Económicos (OECD, 2021) señala que los marcos de madurez permiten a las organizaciones evaluar su estado actual en el uso

de IA y planificar rutas de evolución coherentes con sus capacidades técnicas, organizacionales y de gobernanza.

4.3. Teorías contemporáneas de adopción tecnológica

Para analizar la adopción de ML en organizaciones financieras, es necesario apoyarse en teorías consolidadas de adopción tecnológica.

El Modelo de Aceptación Tecnológica (TAM), propuesto por Davis (1989), plantea que la percepción de utilidad y facilidad de uso influyen en la aceptación de una tecnología. Aunque es un modelo clásico, continúa siendo utilizado como base conceptual en estudios actuales sobre adopción de IA, por su valor explicativo a nivel individual.

La Teoría de Difusión de Innovaciones de Rogers (1983) explica la adopción tecnológica como un proceso gradual, influenciado por categorías como innovators y early adopters. La adopción de tecnologías basadas en IA se desarrolla de manera progresiva dentro de las organizaciones, influenciada por actores internos que actúan como early adopters y por el liderazgo tecnológico, facilitando la difusión de la innovación y reduciendo la resistencia al cambio (Rogers, 1983; OECD, 2021).

Por su parte, el marco TOE (Technology–Organization–Environment) continúa siendo ampliamente utilizado en estudios recientes sobre adopción de inteligencia artificial. Dwivedi et al. (2021) señalan que los factores tecnológicos, organizacionales y del entorno explican de manera integral la adopción de sistemas basados en IA en organizaciones, especialmente en sectores altamente regulados, donde aspectos como

infraestructura, capacidades organizacionales y presión regulatoria influyen significativamente en la implementación de estas tecnologías.

4.4. Modelos de madurez para inteligencia artificial y analítica avanzada

Los modelos de madurez han adquirido relevancia en la literatura reciente sobre inteligencia artificial como herramientas para comprender la adopción progresiva de estas tecnologías en las organizaciones. Organismos internacionales como la Organización para la Cooperación y el Desarrollo Económicos (OECD, 2021) destacan que la madurez en inteligencia artificial depende del desarrollo equilibrado de capacidades técnicas, organizacionales y humanas, permitiendo a las empresas evaluar su estado actual y planificar rutas de evolución coherentes con sus recursos y contexto institucional.

De forma complementaria, Alsheibani et al. (2020) proponen el concepto de AI readiness como un marco para evaluar la preparación organizacional frente a la adopción de inteligencia artificial. Este enfoque resalta que dimensiones como la estrategia, la gobernanza de datos, la cultura organizacional y la disponibilidad de talento especializado son determinantes del nivel de madurez alcanzado.

En el ámbito de la analítica avanzada, Grover et al. (2022) señalan que los modelos de madurez permiten evaluar la capacidad de las organizaciones para generar valor a partir de los datos, destacando la necesidad de integrar técnicas de machine learning en la toma de decisiones estratégicas. Estos enfoques refuerzan la pertinencia de diseñar un modelo de madurez específico para el sector financiero colombiano.

4.5. Dimensiones Clave para la adopción de Machine Learning

A partir de la revisión de la literatura, se identifican cinco dimensiones centrales que influyen de manera determinante en la adopción efectiva del machine learning (ML) en organizaciones del sector financiero. Estas dimensiones reflejan que la adopción de ML no es únicamente un desafío tecnológico, sino un proceso organizacional integral que involucra decisiones estratégicas, capacidades estructurales y factores culturales.

4.5.1. Estrategia

La alineación entre las iniciativas de machine learning y la estrategia organizacional es un factor crítico para la generación de valor sostenible. Rai et al. (2021) señalan que las tecnologías digitales avanzadas, incluida la inteligencia artificial, solo producen impactos significativos cuando se integran de manera explícita a los objetivos estratégicos de la organización. En el sector financiero, esto implica que los proyectos de ML deben responder a prioridades claras del negocio, como la gestión del riesgo, la eficiencia operativa, la personalización de servicios o el cumplimiento regulatorio.

La ausencia de una visión estratégica suele derivar en implementaciones fragmentadas o en pilotos aislados que no logran escalar ni generar impacto organizacional. Por el contrario, cuando el ML se incorpora como un habilitador estratégico, las organizaciones pueden definir portafolios de casos de uso priorizados, asignar recursos de manera coherente y establecer mecanismos de seguimiento que conecten los resultados técnicos con indicadores de desempeño del negocio.

4.5.2. Datos

Los datos constituyen el insumo fundamental para el desarrollo de modelos de machine learning, por lo que su calidad, disponibilidad y gobernanza condicionan directamente el éxito de las iniciativas de ML. La OECD (2021) destaca que una adopción madura de inteligencia artificial requiere marcos sólidos de gobernanza de datos que garanticen integridad, trazabilidad, seguridad y uso ético de la información.

En el contexto financiero, los datos suelen estar distribuidos en múltiples sistemas, con diferentes niveles de calidad y restricciones regulatorias. La falta de estandarización, la existencia de silos de información y la ausencia de políticas claras de gobierno de datos dificultan el entrenamiento y despliegue de modelos de ML confiables. En contraste, las organizaciones que avanzan en madurez desarrollan arquitecturas de datos integradas, roles claros de responsabilidad y procesos que permiten reutilizar datos de forma eficiente y segura.

4.5.3. Tecnología

La infraestructura tecnológica y las plataformas analíticas actúan como habilitadores claves para la adopción de machine learning. Dwivedi et al. (2021) señalan que la implementación de sistemas basados en inteligencia artificial requiere no solo herramientas de análisis avanzadas, sino también capacidades para integrar modelos en los sistemas operativos existentes.

En el sector financiero, esta dimensión incluye la disponibilidad de infraestructura computacional, plataformas de desarrollo y despliegue de modelos, así como mecanismos para su monitoreo y mantenimiento. La falta de capacidades tecnológicas adecuadas puede limitar el paso de modelos experimentales a entornos productivos. En

niveles más avanzados de madurez, las organizaciones cuentan con arquitecturas escalables que facilitan la automatización del ciclo de vida del ML, reduciendo la dependencia de soluciones ad hoc.

4.5.4. Talento

La disponibilidad de talento especializado constituye una de las principales barreras para la adopción de machine learning. El Banco Interamericano de Desarrollo (BID, 2021) identifica la escasez de perfiles en ciencia de datos, ingeniería de datos y analítica avanzada como un obstáculo recurrente en América Latina. En el sector financiero, esta limitación se acentúa debido a la necesidad de combinar conocimientos técnicos con comprensión del negocio y del marco regulatorio.

Las organizaciones con mayores niveles de madurez no solo invierten en la contratación de talento especializado, sino también en la formación continua de equipos interdisciplinarios. Además, promueven la colaboración entre áreas técnicas y de negocio, reduciendo la dependencia de expertos individuales y fortaleciendo capacidades internas sostenibles.

4.5.5. Cultura organizacional

La cultura organizacional orientada a datos y a la experimentación es un elemento transversal en la adopción de machine learning. Ransbotham et al. (2020) señalan que la aceptación y el escalamiento de soluciones basadas en IA dependen en gran medida de la disposición de la organización para confiar en los datos, aprender de la experimentación y gestionar el cambio.

En contextos donde prevalece una cultura resistente al cambio o aversa al riesgo, las iniciativas de ML suelen enfrentar barreras internas, independientemente de la calidad técnica de los modelos. Por el contrario, una cultura que fomenta la toma de decisiones basada en datos, el aprendizaje organizacional y la colaboración facilita la integración del ML en los procesos cotidianos y su institucionalización a largo plazo.

4.6. Dimensiones Clave para la adopción de Machine Learning

La adopción de machine learning (ML) en el sector financiero colombiano se encuentra fuertemente condicionada por el marco regulatorio vigente, el cual establece lineamientos estrictos en materia de protección de datos personales, gestión del riesgo, seguridad de la información y transparencia en la toma de decisiones automatizadas. Dado que las entidades financieras operan en un entorno altamente regulado y supervisado, la incorporación de modelos de ML no puede abordarse únicamente desde una perspectiva técnica, sino que debe considerar de manera explícita los requisitos normativos y de control asociados a su uso (OECD, 2021).

Uno de los principales retos regulatorios está relacionado con la protección y el tratamiento de los datos, dado que los modelos de ML dependen de grandes volúmenes de información, en muchos casos de carácter sensible. En este contexto, las exigencias regulatorias influyen directamente en la forma en que las organizaciones recolectan, almacenan, procesan y utilizan los datos, así como en la necesidad de contar con mecanismos de trazabilidad y control que garanticen un uso responsable de la información. La falta de alineación entre los desarrollos técnicos y los marcos normativos puede limitar el despliegue de soluciones de ML, incluso cuando estas presentan un alto potencial de valor para el negocio (OECD, 2021).

Adicionalmente, la creciente utilización de modelos algorítmicos en procesos críticos del sector financiero —como la evaluación de riesgo crediticio, la detección de fraude o la segmentación de clientes— ha puesto de relieve la importancia de la transparencia y la explicabilidad de los sistemas basados en inteligencia artificial. Los marcos regulatorios tienden a exigir que las decisiones automatizadas puedan ser comprendidas, auditadas y justificadas, lo cual representa un desafío adicional para la adopción de modelos de ML complejos y de tipo “caja negra”. Este requisito impacta directamente en la selección de modelos, en los procesos de validación y en la necesidad de incorporar prácticas formales de gobernanza algorítmica (OECD, 2021).

Desde una perspectiva internacional, la Organización para la Cooperación y el Desarrollo Económicos destaca que una regulación basada en principios —en lugar de reglas prescriptivas— puede facilitar la adopción responsable de la inteligencia artificial, especialmente en sectores sensibles como el financiero. Este enfoque promueve un equilibrio entre innovación y control, permitiendo que las organizaciones desarrollen y desplieguen soluciones de ML siempre que se respeten principios fundamentales como la equidad, la transparencia, la seguridad y la rendición de cuentas (OECD, 2021).

En consecuencia, el marco regulatorio no debe entenderse únicamente como una barrera para la adopción de machine learning, sino también como un factor estructurante que influye en la forma en que las organizaciones avanzan en su nivel de madurez. Las entidades financieras con mayores niveles de madurez tienden a integrar los requisitos regulatorios desde las etapas iniciales del diseño de sus modelos, incorporando prácticas

de control, gestión del riesgo y cumplimiento normativo que facilitan una adopción más sostenible y alineada con el entorno regulatorio (OECD, 2021).

4.7. Dimensiones Clave para la adopción de Machine Learning

Con base en la revisión de la literatura, el presente estudio adopta una perspectiva organizacional y evolutiva para analizar la adopción del machine learning (ML) en el sector financiero colombiano. Esta perspectiva reconoce que la adopción de tecnologías avanzadas no constituye un evento aislado ni un proceso meramente técnico, sino una transformación progresiva que involucra múltiples dimensiones organizacionales y se desarrolla a lo largo del tiempo.

Desde el punto de vista teórico, el estudio integra aportes de las teorías de adopción tecnológica con modelos contemporáneos de madurez organizacional en inteligencia artificial. En primer lugar, el Modelo de Aceptación Tecnológica (TAM) permite comprender cómo la percepción de utilidad y facilidad de uso influye en la aceptación inicial de soluciones basadas en ML por parte de los usuarios organizacionales (Davis, 1989). Aunque este modelo se centra en el nivel individual, su inclusión resulta pertinente para explicar las primeras etapas de adopción dentro de las organizaciones.

En segundo lugar, la Teoría de Difusión de Innovaciones aporta una visión evolutiva de la adopción tecnológica, al explicar cómo las innovaciones se propagan de manera gradual dentro de los sistemas sociales y organizacionales. Este enfoque permite entender el papel de los early adopters, del liderazgo tecnológico y de los

mecanismos de aprendizaje organizacional en la expansión del uso del ML más allá de proyectos piloto (Rogers, 1983; OECD, 2021).

Adicionalmente, el marco TOE (Technology–Organization–Environment) ofrece una visión integral para analizar la adopción del ML en organizaciones financieras, al considerar de forma simultánea factores tecnológicos, organizacionales y del entorno. Estudios recientes destacan que este enfoque resulta especialmente adecuado para sectores altamente regulados, donde la infraestructura tecnológica, la capacidad organizacional y las presiones regulatorias influyen de manera conjunta en la implementación de soluciones de inteligencia artificial (Dwivedi et al., 2021).

Finalmente, la incorporación de modelos de madurez en inteligencia artificial permite articular estas teorías en una lógica evolutiva y multidimensional. Desde esta perspectiva, la adopción del ML se concibe como un proceso progresivo en el que las organizaciones desarrollan, de forma gradual, capacidades estratégicas, técnicas, humanas y culturales que les permiten avanzar desde usos exploratorios hacia implementaciones integradas y sostenibles (OECD, 2021; Alsheibani et al., 2020).

En conjunto, esta perspectiva teórica proporciona un marco analítico coherente para abordar la complejidad del fenómeno estudiado, permitiendo analizar la adopción del machine learning como un proceso dinámico y contextualizado. Asimismo, ofrece una base conceptual sólida para el diseño del modelo de madurez propuesto, alineando el análisis teórico con los objetivos del estudio y con las particularidades del sector financiero colombiano.

5. Metodología

5.1. Enfoque de la investigación

El presente estudio adopta un enfoque cualitativo, dado que su propósito principal es comprender, analizar e interpretar el fenómeno de adopción del machine learning (ML) en el sector financiero colombiano desde una perspectiva organizacional y estratégica. Este enfoque resulta pertinente porque la investigación no busca medir variables numéricamente ni establecer relaciones estadísticas, sino explorar cómo las organizaciones desarrollan capacidades, enfrentan barreras y avanzan en niveles de madurez en el uso de ML.

El enfoque cualitativo permite profundizar en los significados, percepciones y estructuras conceptuales que subyacen a la adopción del ML, particularmente en un contexto complejo y regulado como el sector financiero. Asimismo, este enfoque es coherente con el objetivo de diseñar un modelo de madurez, el cual se fundamenta en la integración y análisis de marcos conceptuales, modelos teóricos y evidencia documental más que en la medición cuantitativa de variables.

5.2. Diseño de la investigación

El diseño de la investigación es no experimental, dado que el investigador no manipula deliberadamente ninguna variable ni interviene directamente sobre las organizaciones objeto de estudio. En su lugar, se limita a observar, analizar e interpretar información existente relacionada con la adopción del machine learning en el sector financiero.

Dentro de los diseños no experimentales, el estudio adopta un diseño transversal, ya que la recolección y análisis de la información se realiza en un único momento del tiempo. Este diseño es adecuado considerando que el objetivo es construir una fotografía conceptual del estado actual del conocimiento y las prácticas relacionadas con la adopción de ML, sin pretender analizar su evolución longitudinal ni medir cambios a lo largo del tiempo.

La elección de un diseño no experimental y transversal se justifica además por la naturaleza exploratoria y conceptual del estudio, orientado a la construcción de un modelo de aplicación y no a la evaluación de efectos causales..

5.3. Alcance de la investigación

De acuerdo con el enfoque cualitativo adoptado, el estudio presenta un alcance de análisis de contenido, centrado en la revisión, interpretación y síntesis de documentos académicos, institucionales y sectoriales relacionados con la adopción de inteligencia artificial y machine learning.

El análisis de contenido resulta apropiado porque permite identificar patrones conceptuales, dimensiones clave, enfoques teóricos y elementos comunes presentes en la literatura, los cuales sirven como insumo para el diseño del modelo de madurez propuesto. Este tipo de alcance facilita una comprensión profunda del fenómeno sin recurrir a técnicas estadísticas, alineándose con los objetivos del estudio.

5.4. Definición de variables

En coherencia con el enfoque cualitativo y el objetivo del estudio, las variables no se conciben como variables independientes y dependientes, sino como dimensiones

analíticas interrelacionadas que estructuran el modelo de madurez para la adopción de ML. Estas variables corresponden a los atributos clave que permiten caracterizar el nivel de madurez organizacional.

Las variables definidas para el estudio son:

- Estrategia
- Datos
- Tecnología
- Talento
- Cultura organizacional.

5.5. Definición conceptual y operacional de las variables

A continuación, se presenta la definición conceptual y operacional de las variables del estudio, organizadas en una tabla que permite visualizar de manera clara su significado teórico, su forma de análisis y las dimensiones asociadas.

Variable	Definición conceptual	Definición operacional	Dimensiones
Estrategia	Grado en que el ML se integra a los objetivos y prioridades estratégicas de la organización.	Análisis de documentos y literatura que evidencien alineación entre ML y estrategia organizacional.	Visión estratégica, priorización de casos de uso, gobierno corporativo
Datos	Calidad, disponibilidad y gobernanza de los datos utilizados para ML.	Identificación de prácticas de gestión, gobierno y uso de datos descritas en la literatura.	Calidad de datos, integración, gobernanza
Tecnología	Infraestructura y plataformas que	Análisis de marcos tecnológicos y	Infraestructura, herramientas

	soportan el desarrollo y despliegue de ML.	arquitecturas descritas en estudios sectoriales.	analíticas, escalabilidad
Talento	Capacidades humanas necesarias para desarrollar y operar soluciones de ML.	Revisión de perfiles, roles y competencias identificadas en la literatura.	Formación, experiencia, trabajo interdisciplinario
Cultura organizacional	Valores y prácticas que facilitan la adopción de ML.	Análisis de prácticas culturales descritas en estudios organizacionales.	Orientación a datos, gestión del cambio, aprendizaje organizacional

Tabla 1. Definición conceptual y operacional de las variables

5.6. Población y muestra

Dado el enfoque cualitativo y el alcance del estudio, la población corresponde al universo de documentos relevantes relacionados con la adopción de machine learning e inteligencia artificial en organizaciones, con énfasis en el sector financiero.

La muestra se selecciona de manera intencional y no probabilística, incluyendo:

- Artículos académicos indexados en bases de datos como Scopus y Web of Science.
- Informes de organismos internacionales (OECD, BID, CEPAL).
- Estudios sectoriales sobre transformación digital y adopción de IA en el sector financiero.

La selección de esta muestra se justifica por su pertinencia, actualidad y relevancia académica, garantizando una comprensión profunda y contextualizada del fenómeno estudiado.

5.7. Selección de métodos e instrumentos de recolección de información

La técnica principal de recolección de información es la revisión documental, orientada al análisis sistemático de fuentes secundarias. El instrumento utilizado consiste en una matriz de análisis documental, diseñada para registrar información clave de cada documento revisado.

Esta matriz incluye categorías como: autor, año, contexto del estudio, enfoque teórico, dimensiones analizadas, hallazgos principales y aportes al modelo de madurez. El instrumento permite organizar y comparar la información de manera estructurada y será incluido como anexo al final del documento.

5.8. Técnica de análisis de datos

Para el análisis de la información recolectada se emplea la técnica de análisis de contenido, la cual permite identificar categorías, patrones y relaciones conceptuales presentes en los documentos analizados.

La información se codifica de acuerdo con las variables definidas previamente (estrategia, datos, tecnología, talento y cultura organizacional), facilitando la síntesis y la construcción del modelo de madurez.

Intrumento	Técnica de análisis	Descripción
Matriz documental	Análisis de contenido	Identificación y categorización de conceptos clave para el modelo de madurez

Tabla 2. Instrumentos y técnicas de análisis

5.9. Actividades de la investigación

Finalmente, se presentan las actividades definidas para el cumplimiento de cada objetivo específico del estudio.

Objetivo específico	Actividades
Analizar modelos de madurez existentes	Revisión de literatura; selección de modelos; síntesis comparativa
Identificar barreras y capacidades	Análisis documental; categorización de factores; integración conceptual
Diseñar el modelo de madurez	Definición de dimensiones; construcción de niveles; formulación del modelo
Validar conceptualmente el modelo	Revisión cruzada con literatura; ajuste del modelo; validación teórica

Tabla 3. Definición conceptual y operacional de las variables

6. Modelo de madurez para la adopción de Machine Learning

6.1. Propósito del modelo de madurez

El modelo de madurez propuesto tiene como objetivo diagnosticar el nivel de adopción de machine learning (ML) en organizaciones del sector financiero colombiano, así como orientar su evolución progresiva hacia un uso estratégico y sostenible. El modelo permite identificar brechas organizacionales, priorizar acciones de mejora y apoyar la toma de decisiones relacionadas con inversión en capacidades analíticas.

Desde una perspectiva organizacional y evolutiva, el modelo concibe la adopción del ML como un proceso gradual que involucra dimensiones estratégicas, técnicas, humanas, culturales y regulatorias, y no como un evento aislado o puramente tecnológico.

6.2. Enfoque conceptual del modelo

El modelo se fundamenta en:

- Teorías de adopción tecnológica (TAM, difusión de innovaciones y TOE)
- Modelos contemporáneos de madurez en inteligencia artificial.
- Enfoques institucionales sobre adopción responsable de IA (OECD).

Bajo este enfoque, la madurez organizacional se define como el grado en que una organización desarrolla y articula capacidades para diseñar, implementar, gobernar y escalar soluciones de ML alineadas con su estrategia y con el entorno regulatorio.

6.3. Dimensiones del modelo de madurez

El modelo se estructura en cinco dimensiones, previamente definidas en el marco teórico.

1. Estrategia
2. Datos
3. Tecnología
4. Talento
5. Cultura organizacional

Cada dimensión se evalúa de manera transversal en los distintos niveles de madurez.

6.4. Niveles de madurez propuestos

El modelo contempla cinco niveles progresivos de madurez, que describen la evolución típica de las organizaciones en la adopción de ML.

6.4.1. Nivel 1 – Inicial/Incipiente

La organización presenta un conocimiento limitado sobre machine learning y su potencial. No existe una estrategia clara ni iniciativas formales relacionadas con ML. El uso de analítica es básico y predominantemente descriptivo.

- Estrategia: No hay alineación entre ML y objetivos estratégicos.
- Datos: Datos fragmentados, baja calidad y ausencia de gobernanza.
- Tecnología: Infraestructura limitada, sin herramientas específicas para ML.
- Talento: No existen perfiles especializados.
- Cultura: Alta resistencia al cambio y baja orientación a datos.

6.4.2. Nivel 2 – Exploratorio

La organización comienza a experimentar con ML mediante pilotos o pruebas de concepto aisladas, generalmente impulsadas por áreas técnicas o proveedores externos.

- Estrategia: Interés incipiente, sin hoja de ruta definida.
- Datos: Uso puntual de datos, con procesos manuales.
- Tecnología: Herramientas aisladas, sin integración a sistemas centrales.
- Talento: Dependencia de consultores externos.
- Cultura: Curiosidad tecnológica, pero con escepticismo organizacional.

6.4.3. Nivel 3 – Definido

La organización reconoce el valor estratégico del ML y comienza a estructurar iniciativas formales, alineadas parcialmente con la estrategia del negocio.

- Estrategia: Casos de uso priorizados y alineados con objetivos del negocio.
- Datos: Avances en integración y gobierno de datos.
- Tecnología: Plataformas analíticas más robustas y entornos controlados.

- Talento: Equipos internos básicos y programas de capacitación.
- Cultura: Mayor aceptación del uso de datos en la toma de decisiones.

6.4.4. Nivel 4 – Gestionado

El ML se integra de forma sistemática en procesos clave del negocio y se gestiona mediante prácticas formales de gobernanza, control y medición de valor.

- Estrategia: ML incorporado explícitamente en la estrategia corporativa.
- Datos: Gobierno de datos consolidado y uso transversal.
- Tecnología: Infraestructura escalable y procesos automatizados.
- Talento: Equipos interdisciplinarios consolidados.
- Cultura: Toma de decisiones basada en datos y aprendizaje continuo.

6.4.5. Nivel 5 – Optimizado

La organización utiliza ML como una capacidad estratégica avanzada y diferenciadora, con procesos de mejora continua e innovación constante.

- **Estrategia:** ML como ventaja competitiva sostenible.
- **Datos:** Datos tratados como activo estratégico.
- **Tecnología:** Arquitecturas avanzadas y optimización continua.
- **Talento:** Desarrollo y retención de talento altamente especializado.
- **Cultura:** Cultura de innovación, experimentación y adaptación permanente.

6.5. Matriz de madurez del modelo

El modelo puede representarse mediante una matriz de madurez, donde cada dimensión se evalúa frente a los cinco niveles propuestos. Esta matriz permite realizar diagnósticos organizacionales y visualizar brechas de manera estructurada.

6.6. Uso del modelo de madurez

El modelo está diseñado para ser utilizado como:

- Herramienta de **autodiagnóstico organizacional**.
- Guía para la **planificación estratégica de iniciativas de ML**.
- Marco de referencia para **evaluar el progreso en el tiempo**.
- Insumo para procesos de **toma de decisiones gerenciales**.

Asimismo, el modelo puede adaptarse a distintos tamaños de organización dentro del sector financiero, incluyendo bancos tradicionales y fintech.

6.7. Validación conceptual del modelo

La validación del modelo se realiza de manera **conceptual y teórica**, contrastando sus dimensiones y niveles con la literatura académica y los marcos institucionales revisados. Esta validación permite asegurar coherencia interna, pertinencia sectorial y consistencia con las teorías de adopción tecnológica.

6.8. Aporte del modelo al estudio

El modelo de madurez propuesto constituye el principal aporte del estudio, al ofrecer una estructura clara y contextualizada para comprender y gestionar la adopción del *machine learning* en el sector financiero colombiano. Su enfoque progresivo facilita la transición desde iniciativas exploratorias hacia implementaciones estratégicas y sostenibles.

6.9. Matriz evaluable del modelo de madurez

La siguiente matriz permite evaluar el nivel de madurez en adopción de Machine Learning de una organización del sector financiero, considerando las cinco dimensiones definidas y los cinco niveles progresivos del modelo.

Dimensión	Nivel 1 - Inicial	Nivel 2 – Exploratorio	Nivel 3 – Definido	Nivel 4 – Gestionado	Nivel 5 - Optimizado
Estrategia	No existe visión ni objetivos relacionados con ML.	Interés incipiente; pilotos aislados sin hoja de ruta.	Casos de uso priorizados y parcialmente alineados con la estrategia.	ML integrado explícitamente en la estrategia corporativa.	ML como ventaja competitiva y motor de innovación continua.
Datos	Datos fragmentados, baja calidad y sin gobierno.	Uso puntual de datos con procesos manuales.	Integración parcial de datos y políticas iniciales de gobernanza.	Gobierno de datos consolidado y uso transversal.	Datos tratados como activo estratégico y reutilizable.
Tecnología	Infraestructura limitada, sin herramientas de ML.	Herramientas aisladas, sin integración operativa.	Plataformas analíticas estables para desarrollo controlado.	Infraestructura escalable con automatización del ciclo de ML.	Arquitecturas avanzadas y optimización continua.
Talento	Ausencia de perfiles especializados en ML.	Dependencia de consultores externos.	Equipos internos básicos y programas de capacitación.	Equipos interdisciplinarios consolidados.	Desarrollo y retención de talento altamente especializado.
Cultura Organizacional	Resistencia al cambio y decisiones basadas en intuición.	Curiosidad tecnológica con escepticismo organizacional.	Mayor aceptación del uso de datos en decisiones.	Cultura data-driven y aprendizaje organizacional.	Cultura de innovación, experimentación y mejora continua.

Tabla 4. Definición conceptual y operacional de las variables

Uso de la Matriz: Cada dimensión se evalúa identificando el nivel que mejor represente la situación actual de la organización. El nivel global de madurez puede determinarse por promedio, mediana o por el nivel mínimo alcanzado entre dimensiones (criterio conservador).

6.10. Instrumento de diagnóstico del modelo de madurez

Para utilizar el modelo, se propone un instrumento de diagnóstico tipo checklist con escala ordinal, alineado con el enfoque cualitativo y el análisis de contenido definido en la metodología.

6.10.1. Tipo de instrumento

- Instrumento: Lista de verificación con escala de madurez
- Aplicación: Autoevaluación organizacional o evaluación por expertos
- Escala: 1 a 5 (correspondiente a los niveles del modelo)
- Unidad de análisis: Organización del sector financiero (banco o fintech)

6.10.2. Escala de valoración

Instrumento	Técnica de análisis
1	Inicial
2	Exploratorio
3	Definido
4	Gestionado
5	Optimizado

Tabla 5. Escala de valoración

6.10.3. Instrumento de diagnóstico por dimensión

Ítem	Pregunta de Evaluación	Puntaje (1-5)
E1	¿La organización cuenta con una visión explícita sobre el uso de ML?	
E2	Exploratorio ¿Existen casos de uso de ML alineados con objetivos estratégicos?	
E3	¿El ML está integrado en la planeación estratégica o roadmap digital?	

Tabla 6. Estrategia

Ítem	Pregunta de Evaluación	Puntaje (1-5)
D1	¿La organización dispone de datos integrados y de calidad para ML?	
D2	¿Existen políticas formales de gobernanza de datos?	
D3	¿Los datos se reutilizan de manera transversal entre áreas?	

Tabla 7. Datos

|

Ítem	Pregunta de Evaluación	Puntaje (1-5)
T1	¿La organización cuenta con infraestructura adecuada para ML?	

T2	¿Los modelos de ML se integran a sistemas operativos?	
T3	¿Existen procesos automatizados para el ciclo de vida del ML?	

Tabla 8. Tecnología

Ítem	Pregunta de Evaluación	Puntaje (1-5)
TA1	¿La organización cuenta con perfiles especializados en ML?	
TA2	¿Existen programas de formación continua en analítica avanzada?	
TA3	¿Los equipos de ML trabajan de forma interdisciplinaria?	

Tabla 9. Talento

Ítem	Pregunta de Evaluación	Puntaje (1-5)
C1	¿Las decisiones organizacionales se basan en datos y análisis?	
C2	¿Existe apertura al uso de modelos predictivos en procesos clave?	
C3	¿La organización fomenta la experimentación y el aprendizaje?	

Tabla 10. Cultura Organizacional

6.10.4. Interpretación de resultados

- Puntaje por dimensión: Promedio de los ítems de cada dimensión

- Nivel de madurez global: Promedio general o Nivel mínimo alcanzado entre dimensiones (criterio recomendado en sectores regulados)

6.11. Recomendaciones de evolución por nivel de madurez

Este apartado traduce el modelo de madurez en orientaciones prácticas, permitiendo a las organizaciones del sector financiero identificar acciones prioritarias para avanzar de un nivel a otro. Las recomendaciones se estructuran por nivel y consideran las cinco dimensiones del modelo.

6.11.1. Nivel 1 → Nivel 2: De Inicial a Exploratorio

Objetivo: Generar conciencia organizacional y capacidades mínimas para iniciar la adopción de ML.

- Estrategia:
 - Sensibilizar a la alta dirección sobre el potencial del ML en el sector financiero.
 - Identificar oportunidades de uso a nivel exploratorio (fraude, riesgo, eficiencia).
- Datos:
 - Inventariar fuentes de datos existentes y evaluar su calidad básica.
 - Definir responsables iniciales de gestión de datos.
- Tecnología:
 - Implementar herramientas analíticas básicas o entornos de experimentación controlados.
 - Evitar inversiones tecnológicas de gran escala en esta etapa.

- Talento:
 - Capacitar perfiles existentes en fundamentos de analítica y ML.
 - Apoyarse temporalmente en consultores externos.
- Cultura:
 - Fomentar una cultura de aprendizaje y exploración tecnológica.
 - Comunicar expectativas realistas sobre el alcance inicial del ML.

6.11.2. Nivel 2 → Nivel 3: De Exploratorio a Definido

Objetivo: Formalizar iniciativas y comenzar la alineación estratégica.

- Estrategia:
 - Definir una hoja de ruta inicial de ML alineada con objetivos del negocio.
 - Priorizar casos de uso con impacto medible.
- Datos:
 - Iniciar procesos de integración de datos y establecer normas básicas de calidad.
 - Definir políticas preliminares de gobernanza de datos.
- Tecnología:
 - Seleccionar plataformas analíticas estables para desarrollo y pruebas.
 - Documentar arquitecturas y flujos de datos.
- Talento:

- Crear equipos internos básicos de analítica y ML.
- Establecer planes de formación continua.
- Cultura:
 - Promover el uso de datos en la toma de decisiones tácticas.
 - Reducir la resistencia al cambio mediante resultados tempranos.

6.11.3. Nivel 3 → Nivel 4: De Definido a Gestionado

- Objetivo: Integrar ML de forma sistemática en procesos clave.
- Estrategia:
 - Incorporar ML explícitamente en la planeación estratégica.
 - Establecer indicadores de valor y retorno de inversión.
- Datos:
 - Consolidar un modelo formal de gobierno de datos.
 - Garantizar trazabilidad y cumplimiento regulatorio.
- Tecnología:
 - Automatizar el ciclo de vida del ML (desarrollo, despliegue, monitoreo).
 - Integrar modelos a sistemas operativos.
- Talento:
 - Fortalecer equipos interdisciplinarios (negocio + tecnología).
 - Reducir dependencia de proveedores externos.
- Cultura:
 - Institucionalizar la toma de decisiones basada en datos.
 - Incentivar el aprendizaje organizacional.

6.11.4. Nivel 4 → Nivel 5: De Gestionado a Optimizado

- Objetivo: Consolidar ML como capacidad estratégica avanzada.
- Estrategia:
 - Utilizar ML como fuente de diferenciación competitiva.
 - Explorar nuevos modelos de negocio basados en analítica avanzada.
- Datos:
 - Tratar los datos como activos estratégicos.
 - Promover reutilización y analítica avanzada transversal.
- Tecnología:
 - Optimizar arquitecturas y adoptar enfoques avanzados (MLOps).
 - Implementar mejora continua de modelos.
- Talento:
 - Desarrollar programas de retención y especialización avanzada.
 - Fomentar liderazgo analítico.
- Cultura:
 - Consolidar una cultura de innovación permanente.
 - Incentivar la experimentación responsable.

6.12. Plan de validación y aplicación del modelo de madurez

6.12.1. Tipo de Validación

La validación del modelo es de tipo conceptual y cualitativa, dado que el estudio no contempla experimentación ni medición estadística. La validación busca evaluar:

- Coherencia interna del modelo.

- Pertinencia de las dimensiones y niveles.
- Aplicabilidad al sector financiero colombiano.

6.12.2. Estrategias de validación

Se proponen las siguientes estrategias:

a) Validación por contraste teórico

- Comparación del modelo con marcos existentes de adopción de IA y ML.
- Verificación de consistencia con teorías de adopción tecnológica y madurez organizacional.

b) Validación por juicio de expertos

- Revisión del modelo por expertos en analítica, ML y sector financiero.
- Evaluación cualitativa de claridad, pertinencia y utilidad del modelo.

c) Validación mediante aplicación piloto (opcional)

- Aplicación exploratoria del instrumento de diagnóstico en una entidad financiera.
- Análisis cualitativo de resultados y ajuste conceptual del modelo.

6.12.3. Aplicación del modelo

El modelo puede aplicarse como:

- Herramienta de autodiagnóstico organizacional

- Guía para planeación estratégica de ML
- Marco de referencia para evaluación de capacidades analíticas
- Insumo para procesos de transformación digital

6.12.4. Resultados esperados de la aplicación

- Identificación clara del nivel de madurez organizacional.
- Detección de brechas por dimensión.
- Definición de prioridades de intervención.
- Soporte para decisiones estratégicas y de inversión.

7. Conclusiones

El presente estudio tuvo como propósito diseñar un modelo de madurez para la adopción de machine learning en organizaciones del sector financiero colombiano, partiendo del reconocimiento de que la incorporación de estas tecnologías constituye un proceso organizacional complejo y progresivo. A partir del análisis teórico y documental realizado, se concluye que la adopción efectiva del ML no depende exclusivamente de la disponibilidad tecnológica, sino de la articulación equilibrada de múltiples dimensiones organizacionales.

En primer lugar, se evidencia que existe una brecha significativa entre el interés estratégico de las organizaciones financieras por el uso del machine learning y su capacidad real para implementarlo de manera sostenible. Esta brecha se manifiesta en la prevalencia de iniciativas exploratorias y pilotos aislados, que carecen de integración con la estrategia organizacional y presentan limitaciones en términos de escalabilidad y generación de valor.

En segundo lugar, el análisis de la literatura permitió identificar que la adopción del ML está condicionada por cinco dimensiones centrales: estrategia, datos, tecnología, talento y cultura organizacional. Estas dimensiones interactúan de forma sistémica y su desarrollo desigual limita el avance en los niveles de madurez. En particular, la falta de gobernanza de datos, la escasez de talento especializado y la resistencia cultural al cambio emergen como barreras recurrentes en el contexto del sector financiero colombiano.

Asimismo, se concluye que los marcos regulatorios desempeñan un papel determinante en la adopción del machine learning en el sector financiero. Lejos de constituir únicamente una restricción, la regulación actúa como un factor estructurante que influye en la forma en que las organizaciones diseñan, validan y despliegan soluciones basadas en ML, especialmente en procesos críticos como la gestión del riesgo y la toma de decisiones automatizadas.

El modelo de madurez propuesto permite abordar estas complejidades de manera estructurada, al ofrecer una visión evolutiva que describe cinco niveles progresivos de adopción. Este enfoque facilita la comprensión de la adopción del ML como un proceso continuo de desarrollo de capacidades organizacionales, más que como una meta tecnológica puntual. En este sentido, el modelo proporciona un marco conceptual coherente para diagnosticar el estado actual de las organizaciones y orientar su evolución hacia un uso estratégico del machine learning.

Finalmente, se concluye que el enfoque cualitativo y el análisis de contenido adoptados resultan adecuados para el alcance del estudio, al permitir la integración de teorías de adopción tecnológica, modelos de madurez y evidencia sectorial. Si bien el modelo no ha sido validado empíricamente a gran escala, su coherencia teórica y su alineación con el contexto del sector financiero colombiano respaldan su pertinencia y utilidad como herramienta de referencia.

REFERENCIAS

Asobancaria. (2021). Capital intelectual. Asociación Bancaria y de Entidades Financieras de Colombia.

<https://www.asobancaria.com/wp-content/uploads/2021/09/Capital%20Intelectual.pdf>

Banco Interamericano de Desarrollo. (2021). La inteligencia artificial al servicio del bien social en América Latina y el Caribe.

<https://publications.iadb.org/es/publications/english/viewer/Artificial-Intelligence-for-Social-Good-in-Latin-America-and-the-Caribbean-The-Regional-Landscape-and-12-Country-Snapshots.pdf>

CEPAL. (2022). Transformación digital, automatización e inteligencia artificial en América Latina. Naciones Unidas.

<https://edigital.economia.gob.sv/wp-content/uploads/2022/01/Tecnologias-digitales-para-un-nuevo-futuro-CEPAL.pdf>

CEPAL. (2025). Transformación digital, automatización e inteligencia artificial en América Latina. Naciones Unidas.

<https://repositorio.cepal.org/server/api/core/bitstreams/e4ca636c-2b8a-4138-8c62-b685540d9b99/content>

Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3), 319–340.

<https://parsmodir.com/wp-content/uploads/2018/11/TAM-Davis-1989.pdf>

Deloitte. (2023). State of AI in the Enterprise, 5th edition. Deloitte Insights.

<https://www.deloitte.com/uk/en/Industries/technology/research/state-of-aiin-the-enterprise-5th-edition.html>

Dwivedi, Y. K., Hughes, L., Ismagilova, E., Aarts, G., Coombs, C., Crick, T., ... Williams, M. D. (2021). Artificial intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research. *International Journal of Information Management*, 57, 101994.

<https://doi.org/10.1016/j.ijinfomgt.2019.08.002>

Gómez Mont, C., Del Pozo, C. M., Martínez Pinto, C., & Martín del Campo Alcocer, A. V. (2020). La inteligencia artificial al servicio del bien social en América Latina y el Caribe: Panorámica regional e instantáneas de doce países. Banco Interamericano de Desarrollo.

<https://publications.iadb.org/es/publications/spanish/viewer/La-inteligencia-artificial-al-servicio-del-bien-social-en-America-Latina-y-el-Caribe-Panor%C3%A1mica-regional-e-instant%C3%A1neas-de-doce-paises.pdf>

Grover, V., Chiang, R. H. L., Liang, T.-P., & Zhang, D. (2022). Creating strategic business value from big data analytics: A research framework. *Journal of Management Information Systems*, 39(2), 388–423.

https://files.stample.com/stample-1564010096810-2868103_1_bda-2018.pdf

Jordan, V., & Poveda, L. (2025). Uso de soluciones de IA en América Latina y el Caribe 2025. Observatorio de Desarrollo Digital, CEPAL.

https://desarrollodigital.cepal.org/es/datos-y-hechos/uso-de-soluciones-de-ia-en-america-latina-y-el-caribe-2025?utm_source=chatgpt.com

McKinsey & Company. (2018). AI adoption advances, but foundational barriers remain. McKinsey Digital.

<https://www.mckinsey.com/featured-insights/artificial-intelligence/ai-adoption-advances-but-foundational-barriers-remain#/>

OECD. (2021). State of implementation of the OECD AI Principles. OECD Publishing.

https://www.oecd.org/content/dam/oecd/en/publications/reports/2021/06/state-of-implementation-of-the-oecd-ai-principles_38a4a286/1cd40c44-en.pdf

Rai, A., Constantinides, P., & Sarker, S. (2021). Editor's comments: Next-generation digital platforms. *MIS Quarterly*, 45(1), iii–ix.

<https://doi.org/10.25300/MISQ/2019/431E0>

Ransbotham, S., Gerbert, P., Reeves, M., Kiron, D., & Spira, M. (2020). Expanding AI's impact with organizational learning. *MIT Sloan Management Review*, 61(4), 1–10.

<https://web-assets.bcg.com/1e/4f/925e66794465ad89953ff604b656/mit-bcg-expanding-ai-impact-with-organizational-learning-oct-2020-n.pdf>

Rogers, E. M. (1983). *Diffusion of innovations* (3th ed.). Free Press.

<https://teddykw2.wordpress.com/wp-content/uploads/2012/07/everett-m-rogers-diffusion-of-innovations.pdf>

Alsheibani, S., Cheung, Y., & Messom, C. (2020). Artificial intelligence adoption: AI readiness at firm level. *International Journal of Information Management*, 55, 102213.

https://researchmgt.monash.edu/ws/portalfiles/portal/273209396/254798983_oa.pdf

ANEXOS