

# UNEMI

UNIVERSIDAD ESTATAL DE MILAGRO

REPÚBLICA DEL ECUADOR

UNIVERSIDAD ESTATAL DE MILAGRO

VICERRECTORADO DE INVESTIGACIÓN Y POSGRADO

PROYECTO DE INVESTIGACIÓN Y DESARROLLO PREVIO A LA OBTENCIÓN DEL  
TÍTULO DE:

**Magíster en Sistemas de Información con Mención en Inteligencia  
de Negocios y Analítica de Datos Masivos**

**TEMA:**

Modelo de adopción de Analítica de Datos Masivos en una Universidad del Ecuador

**Autor:**

Richard Iván Ramírez Anormaliza

**Director:**

**Ing. Jorge Vinueza Martínez, MGTI**

*Milagro, 2023*

## Derechos de autor

Sr. Dr.

**Fabricio Guevara Viejó**

Rector de la Universidad Estatal de Milagro  
Presente.

Yo, **Richard Iván Ramírez Anormaliza** en calidad de autor y titular de los derechos morales y patrimoniales de este informe de investigación, mediante el presente documento, libre y voluntariamente cedo los derechos de Autor de este proyecto de desarrollo, que fue realizada como requisito previo para la obtención de mi Grado, de **Magíster en Sistemas de Información con Mención en Inteligencia de Negocios y Analítica de Datos Masivos**, como aporte a la Línea de Investigación **Sociedad de la información: gestión, medios y tecnología** de conformidad con el Art. 114 del Código Orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación, concedo a favor de la Universidad Estatal de Milagro una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos. Conservo a mi favor todos los derechos de autor sobre la obra, establecidos en la normativa citada.

Así mismo, autorizo a la Universidad Estatal de Milagro para que realice la digitalización y publicación de este Proyecto de Investigación en el repositorio virtual, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

El autor declara que la obra objeto de la presente autorización es original en su forma de expresión y no infringe el derecho de autor de terceros, asumiendo la responsabilidad por cualquier reclamación que pudiera presentarse por esta causa y liberando a la Universidad de toda responsabilidad.

Milagro, **2 de junio del 2023**

**Richard Iván Ramírez Anormaliza**

**C.I.: 1203238132**

## Aprobación del director del trabajo de titulación

Yo, **Jorge Luis Vinueza Martínez** en mi calidad de director del trabajo de titulación, elaborado por **Richard Iván Ramírez Anormaliza**, cuyo tema es **Modelo de adopción de Analítica de Datos Masivos en una Universidad del Ecuador**, que aporta a la Línea de Investigación **Sociedad de la información: gestión, medios y tecnología**, previo a la obtención del Grado **Magíster en Sistemas de Información con Mención en Inteligencia de Negocios y Analítica de Datos Masivos**. Trabajo de titulación que consiste en una propuesta innovadora que contiene, como mínimo, una investigación exploratoria y diagnóstica, base conceptual, conclusiones y fuentes de consulta, considero que el mismo reúne los requisitos y méritos necesarios para ser sometido a la evaluación por parte del tribunal calificador que se designe, por lo que lo **APRUEBO**, a fin de que el trabajo sea habilitado para continuar con el proceso de titulación de la alternativa de Informe de Investigación de la Universidad Estatal de Milagro.

Milagro, 3 de junio del 2023

---

**Jorge Luis Vinueza Martínez**

**C.I.: 0916860588**

**VICERRECTORADO DE INVESTIGACIÓN Y POSGRADO**  
**DIRECCIÓN DE POSGRADO**  
**ACTA DE SUSTENTACIÓN**  
**MAESTRÍA EN SISTEMAS DE INFORMACIÓN**

En la Dirección de Posgrado de la Universidad Estatal de Milagro, a los siete días del mes de agosto del dos mil veintitres, siendo las 10:00 horas, de forma VIRTUAL comparece el/la maestrante, ING. RAMIREZ ANORMALIZA RICHARD IVAN, a defender el Trabajo de Titulación denominado " **MODELO DE ADOPCIÓN DE ANALÍTICA DE DATOS MASIVOS EN UNA UNIVERSIDAD DEL ECUADOR**", ante el Tribunal de Calificación integrado por: Ph. D. FRANCO ARIAS OMAR ORLANDO, Presidente(a), Mgti. CHACON LUNA ANA EVA en calidad de Vocal; y, M.A.E. VINUEZA MORALES MARIUXI GEOVANNA que actúa como Secretario/a.

Una vez defendido el trabajo de titulación; examinado por los integrantes del Tribunal de Calificación, escuchada la defensa y las preguntas formuladas sobre el contenido del mismo al maestrante compareciente, durante el tiempo reglamentario, obtuvo la calificación de: **100.00** equivalente a: **EXCELENTE**.

Para constancia de lo actuado firman en unidad de acto el Tribunal de Calificación, siendo las 11:00 horas.



OMAR ORLANDO FRANCO  
ARIAS

Ph. D. FRANCO ARIAS OMAR ORLANDO  
**PRESIDENTE/A DEL TRIBUNAL**



ANA EVA  
CHACON  
LUNA

Mgti. CHACON LUNA ANA EVA  
**VOCAL**



MARIUXI GEOVANNA  
VINUEZA MORALES

M.A.E. VINUEZA MORALES MARIUXI GEOVANNA  
**SECRETARIO/A DEL TRIBUNAL**



RICHARD IVAN  
RAMIREZ ANORMALIZA

ING. RAMIREZ ANORMALIZA RICHARD IVAN  
**MAGISTER**

## DEDICATORIA

A toda mi familia, de manera especial a Lupe, inspiración y motor.

## AGRADECIMIENTOS

A mis compañeros de curso, fueron un recurso de aprendizaje importante con sus experiencias en este proceso de formación y una mención especial para mis compañeros de grupo en los trabajos de cada módulo.

## Resumen

La adopción de analítica de datos masivos cada vez toma mayor importancia en las universidades para aprovechar la acumulación de datos académicos almacenados en sus sistemas informáticos, así de esta manera mejorar el trabajo de los directivos y ofrecer mejores servicios a los estudiantes; por este motivo fue relevante adaptar un modelo para la adopción de datos masivos partiendo del marco teórico Tecnología-Organización-Entorno. El estudio se realizó entre los directivos de una universidad en Ecuador, la muestra estuvo compuesta por 90 directivos, para el efecto se aplicó un cuestionario en escala Likert de seis puntos y los datos fueron procesados mediante modelo de ecuaciones estructurales con enfoque en mínimos cuadrados parciales, para lo cual se utilizaron las herramientas de software SmartPLS versión 4.0 y el paquete SEMinR en R. El estudio encontró que el contexto tecnológico y el contexto del entorno son factores claves para la adopción de Analítica de Datos Masivos entre los directivos universitarios del Ecuador. La importancia práctica de este resultado radica en que los principales directivos de las universidades deben atender a estos factores identificados en el estudio y así garantizar el éxito de la implementación de esta importante herramienta como lo es la analítica de datos masivos (big data).

**Palabras Clave:** biga data, tecnología-organización-entorno, analítica de datos masivos, PLS-SEM.

## Abstract

The adoption of big data analytics is becoming increasingly important in universities to take advantage of the accumulation of academic data stored in their computer systems, thus improving the work of managers and offering better services to students; for this reason it was relevant to adapt a model for the adoption of massive data based on the theoretical framework Technology-Organization-Environment. The study was carried out among the managers of a university in Ecuador, the sample consisted of 90 managers, for this purpose a questionnaire on a six-point Likert scale was applied and the data were processed using a structural equation model with a partial least squares approach, for which the SmartPLS version 4.0 software tools and the SEMinR package in R were used. The study found that the technological context and the context of the environment are key factors for the adoption of Big Data Analytics among university managers. s from Ecuador. The practical importance of this result lies in the fact that the main managers of the universities must attend to these factors identified in the study and thus guarantee the success of the implementation of this important tool such as big data analytics.

**Keywords:** big data, technology-organization-environment, big data analytics, PLS-SEM.

## Lista de Figuras

<b>Figura 1:</b> Modelo de investigación.....	20
<b>Figura 2:</b> Evaluación preliminar del modelo (Calculado con paquete SEMinR en R) .....	22
<b>Figura 3:</b> Fiabilidad de constructo (Dibujado con SEMinR).....	24
<b>Figura 4:</b> Evaluación del modelo (Dibujado con SEMinR) .....	27
<b>Figura 5:</b> Distribución de los errores de predicción (con uso de predict_pls() y plot()) .....	28

## Lista de Tablas

<b>Tabla 1:</b> Operacionalización de variables .....	7
<b>Tabla 2:</b> Teorías y modelos para evaluar la adopción analítica de datos masivos .....	12
<b>Tabla 3:</b> Variables e indicadores .....	16
<b>Tabla 4:</b> Consideraciones modelamiento SEM-PLS .....	17
<b>Tabla 5:</b> Índices de ajuste global del modelo .....	17
<b>Tabla 6:</b> Índices para la valoración del modelo de medida .....	18
<b>Tabla 7:</b> Índices para la valoración del modelo estructural .....	19
<b>Tabla 8:</b> Resumen de respuestas recibidas.....	21
<b>Tabla 9:</b> Fiabilidad individual de indicadores .....	23
<b>Tabla 10:</b> Fiabilidad y validez de constructo .....	23
<b>Tabla 11:</b> Validez convergente .....	24
<b>Tabla 12:</b> Validez discriminante - Fornell-Larcker .....	25
<b>Tabla 13:</b> Cargas cruzadas del modelo .....	25
<b>Tabla 14:</b> Valores FIV del modelo estructural .....	26
<b>Tabla 15:</b> Coeficientes de senderos .....	26
<b>Tabla 16:</b> Tamaños de los efectos.....	27
<b>Tabla 17:</b> Resumen de los estadísticos predictivos .....	29
<b>Tabla 18:</b> Comparación de RMSE (PLS y LM).....	29

## Lista de Siglas / Acrónimos

3-TUM	Modelo de tres niveles del uso de la tecnología
$\alpha$	Alfa de Cronbach
AVE	Varianza media extraída
BI	Intención de comportamiento
CB	Enfoque de Covarianzas
$f^2$	Valoración de los tamaños de los efectos
FIV	Factor de inflación de la varianza
IS	Sistema de información
M	Media de la muestra
MBC	Modelo basado en análisis las covarianzas
MPLUS	Regresión y análisis de mediación uso
NFI	Índice de ajuste normado
NS	No significativo
O	Muestra original
OECD	Organización para la cooperación económica y el desarrollo
OLAT	El aprendizaje en línea y la formación
OLS	Mínimos cuadrados ordinales
PATH	Modelos de trayectoria, senderos
$\rho_A$ (rho_A)	Índice dijkstra-henseler's
$\rho_c$	Fiabilidad compuesta
PDA	Dispositivos asistentes personales
PE	Entretenimiento percibido
PEOU	Facilidad de uso percibido
PLS	Mínimos cuadrados parciales
PU	Utilidad percibida
$Q^2$	Stone-geisser, índice de relevancia predictiva de un modelo PLS
QWL	Calidad de vida laboral
$R^2$	Valoración del coeficiente de determinación
REL	Relevancia del trabajo
RES	Demostración de resultados
RMS Theta	Medio de la raíz cuadrada de correlación de error
SEM	Modelo de ecuaciones estructurales
Sig.	Significancia estadística
SPSS	Paquete software estadístico para las ciencias sociales

SRMR	Normalización de raíz cuadrada media residual
STDEV	Desviación estándar
SU	Uso del sistema
TAM	Modelo de aceptación de la tecnología
TCC	Terapia cognitivo conductual
TIC	Tecnología de información y comunicación
TPB	Modelo teoría de la conducta planificada
TRA	Teoría de acción razonada
TTF	Modelo de ajuste de tareas-tecnológicas
URL	Localizador de recursos uniforme
USE	Intensidad de uso
UTAUT	Teoría unificada de aceptación y uso de tecnología

## Índice / Sumario

### Contenido

Introducción .....	1
Capítulo I: El problema de la investigación.....	3
1.1 Planteamiento del problema .....	3
1.2 Delimitación del problema.....	4
1.3 Formulación del problema .....	5
1.4 Preguntas de investigación.....	5
1.5 Determinación del tema .....	5
1.6 Objetivos .....	6
1.6.1 Objetivo general.....	6
1.6.2 Objetivos específicos .....	6
1.7 Hipótesis.....	6
1.8 Declaración de las variables (operacionalización) .....	7
1.9 Justificación .....	8
1.10 Alcance y limitaciones .....	9
CAPÍTULO II: Marco teórico referencial .....	10
2.1. Marco teórico.....	10
2.1.1. Antecedentes Históricos .....	10
2.1.2. Antecedentes referenciales .....	10
2.2. Marco legal.....	11
2.3. Marco conceptual .....	11
2.3.1. Datos masivos .....	11
2.3.2. Técnicas para evaluar y predecir adopción de tecnología .....	11
2.3.3. Teoría de la Difusión de la Innovación (DOI).....	12
2.3.4. Modelo de aceptación de la tecnología (TAM) .....	12
2.3.5. Tecnología–organización–medio ambiente (TOE) .....	13
2.3.6. Modelo de ajuste de tareas tecnológicas (TTF) .....	13
CAPÍTULO III: Diseño metodológico .....	14
3.1. Tipo y diseño de investigación.....	14
3.2. La población y la muestra .....	14
3.2.1. Características de la población.....	14
3.2.2. Delimitación de la población.....	14
3.3. Los métodos y las técnicas.....	15
3.3.1. Métodos teóricos .....	15
3.3.2. Métodos empíricos .....	15

3.3.3. Instrumentos.....	15
3.3.4. Técnicas.....	15
3.3.5. Modelo de ecuaciones estructurales enfoque PLS .....	17
6.4.5. Valoración del modelo de medida .....	17
6.4.6. Valoración del modelo estructural .....	18
3.3.6. Consideraciones éticas.....	20
3.4. Procesamiento estadístico de la información.....	20
<b>CAPÍTULO IV: Análisis e interpretación de resultados .....</b>	<b>21</b>
3.5. Introducción.....	21
3.6. Revisión preliminar del modelo.....	21
3.7. Valoración global del modelo.....	22
3.8. Valoración del modelo de medida.....	23
3.8.1. Fiabilidad individual de los indicadores .....	23
3.8.2. Fiabilidad del constructo .....	23
3.8.3. Validez Convergente .....	24
3.8.4. Validez Discriminante.....	24
3.9. Valoración del modelo estructural - hipótesis.....	26
3.9.1. Valoración de la colinealidad .....	26
3.9.2. Evaluación de los coeficientes de senderos (hipótesis) .....	26
3.9.3. Valoración del coeficiente de determinación .....	26
3.9.4. Valoración de los tamaños de los efectos.....	27
3.9.5. Valoración de la relevancia predictiva .....	28
<b>CAPÍTULO V: Conclusiones, Discusión y Recomendaciones .....</b>	<b>30</b>
5.1 Conclusiones.....	30
5.2 Discusión.....	31
5.3 Recomendaciones.....	31
Bibliografía.....	33

## Introducción

La adopción de analíticas de datos masivos (ADM) es un proceso a través del cual las empresas encuentran formas innovadoras de mejorar la productividad y predecir el riesgo para satisfacer las necesidades de los clientes de manera más eficiente (Baig et al., 2019).

Las universidades a nivel mundial, con el paso de los años y el uso de sus diferentes sistemas informáticos almacenan gran cantidad de datos, los mismos que no siempre son explotados para generar ventajas competitivas. Por lo expuesto, se estima importante la adopción de ADM, para aprovechar en incrementar la productividad de la institución con un mejor servicio a sus estudiantes.

El sistema que más datos importantes almacena en la actualidad en las universidades es el sistema de gestión del aprendizaje, también conocido como entorno virtual de aprendizaje ya sea por la aceptación que tienen las carreras en modalidad en línea o por la reciente pandemia que obligo a todos los establecimientos de educación utilizar este tipo de aplicaciones.

Cuantificar la adopción de la ADM entre los directivos de la universidad es importante, ya que permitirá identificar los factores claves que motivan su uso y con ello lograr una implementación exitosa de la herramienta y obtener los múltiples beneficios que ofrece esta tecnología.

Chatterjee et al. (2021) en su estudio identificaron un marco integrado del Modelo de Aceptación de la Tecnología (TAM) desarrollado por Davis (1985) y Tecnología–Organización–Medio ambiente (TOE) propuesto por Tornatzky & Fleisher (1990) para evaluar la adopción de tecnología, propuesta que coincide con el estudio de Sam & Chatwin (2018). Por lo expuesto, para este estudio se eligió TOE como marco de referencia.

Para procesar los datos en TOE, es recomendable utilizar la técnica multivariante modelo de ecuaciones estructurales (SEM) con enfoque en mínimos cuadrados parciales, así lo sugiere la literatura revisada.

En esta investigación se planteó como objetivo principal proponer un modelo para cuantificar la adopción de analítica de datos masivos para el aprovechamiento de los datos académicos en las universidades a partir de TOE.

Con el resultado de esta investigación se espera generar una lista de factores que permitan implementar de manera satisfactoria la ADM en las universidades y a partir de allí estas puede generar una ventaja competitiva.

Como una limitante de la presente investigación se puede considerar que los datos fueron obtenidos solo de una universidad, para aumentar la validez, a futuro se pueden realizar estudios futuros que impliquen una población mayor.

# Capítulo I: El problema de la investigación

## 1.1 Planteamiento del problema

Las universidades en sus procesos académicos y administrativos utilizan sistemas de información y sistemas de gestión del aprendizaje, estos acumulan muchos datos con el paso del tiempo.

Los datos que se almacenan en las universidades son una valiosa fuente de información y su aprovechamiento puede generar oportunidades de mejora a la institución, ayudando a tener una ventaja competitiva (Matthews et al., 2022).

Al-Rahmi et al. (2019) encontraron en su estudio que la intención de compartir la gestión del conocimiento y la intención de usar analítica de datos masivos, contribuyen a sostenibilidad de la. Por lo tanto, es importante adoptar la técnica analítica de datos masivos (ADM) en las universidades.

En la actualidad es nulo o limitado aprovechamiento de los datos almacenados en las universidades. Entre las principales causas tenemos a las siguientes:

- El contexto tecnológico, desconocimiento de las mejoras en la calidad del trabajo que se pueden obtener con la aplicación ADM.
- En el contexto organizacional, no contar con personal capacitado y con experiencia en el uso de ADM
- Falta de apoyo de las autoridades para iniciar proyectos de implementación de ADM.

*Pronostico:* No aprovechar los datos académicos acumulados en las universidades por medio de la adopción de ADM da origen a pérdida de su productividad.

*Control de pronóstico:* Para mejorar la competitividad y brindar mejores servicios a los estudiantes, se deben desarrollar estrategias para ADM en las universidades.

## 1.2 Delimitación del problema

Modelo de Adopción de Analítica de Datos Masivos entre los directivos de una universidad es un estudio planteado con la siguiente delimitación:

- **Espacio**  
En Ecuador, región costa, provincia Guayas, en el cantón San Francisco de Milagro en la Universidad Estatal de Milagro (UNEMI).
- **Universo**  
Los directivos de la Universidad Estatal de Milagro.
- **Línea de investigación**  
Sociedad de la información: gestión, medios y tecnología.
- **Sub-línea de investigación:**  
Análisis, procesamiento y modelamiento de datos.
- **Nivel de educación:**  
Universitario (público).
- **Periodo:**  
2021-2022.

### **1.3 Formulación del problema**

¿Cuáles son los principales factores del limitado aprovechamiento de los datos académicos en las universidades por parte de los directivos?

### **1.4 Preguntas de investigación**

- ¿Cuáles son los constructos que mejor describen la adopción de datos masivos entre los directivos de las universidades?
- ¿Cuáles son los indicadores que permiten medir los constructos que describen la adopción de datos masivos entre los directivos de las universidades?
- ¿Cuál es la influencia que existe entre los constructos que describen la adopción de datos masivos entre los directivos de las universidades?

### **1.5 Determinación del tema**

Modelo de Adopción de Analítica de Datos Masivos en una Universidad del Ecuador.

## **1.6 Objetivos**

### **1.6.1 Objetivo general**

Formular un modelo para cuantificar la adopción de analítica de datos masivos para el aprovechamiento de datos académicos por parte de los directivos de las universidades.

### **1.6.2 Objetivos específicos**

1. Identificar los constructos que mejor describen la adopción de datos masivos entre los directivos de las universidades.
2. Caracterizar los constructos que describen la adopción de datos masivos entre los directivos de las universidades.
3. Analizar la influencia entre los constructos que describen la adopción de datos masivos entre los directivos de las universidades.

## **1.7 Hipótesis**

1. El contexto tecnológico influye en la intención de adoptar ADM entre los directivos universitarios.
2. El contexto organizacional influye en la intención de adoptar ADM entre los directivos universitarios.
3. El contexto ambiental influye en la intención de adoptar ADM entre los directivos universitarios.

## 1.8 Declaración de las variables (operacionalización)

**Tabla 1:** Operacionalización de variables

Variable	Indicadores	Fuente
Contexto Tecnológico (CT).-	CT1 ADM mejora la calidad del trabajo	(Maroufkhani et al., 2020)
	CT2 ADM mejora el servicio a los estudiantes	
	CT3 Aprender a utilizar ADM es fácil para los empleados	
	CT4 ADM es fácil de mantener	
	CT5 Subcontratar ADM genera riesgo de dependencia del proveedor	
	CT6 Mi organización cuenta con computadoras para utilizar ADM	
Contexto Organizacional (CO)	CO1 La infraestructura organizacional posibilita la implementación de ADM	(Sam & Chatwin, 2018)
	CO2 Las autoridades de la universidad apoyan el uso de ADM	
	CO3 El personal de la universidad posee experiencia y habilidades para el uso de ADM	
	CO4 La universidad posee capacidad financiera para invertir en el uso de ADM	
	CO5 La estrategia de la universidad es congruente con el uso de ADM	
Contexto Ambiental (CE)	CE1 Las instituciones de control y acreditación alientan el uso de ADM	(Sun et al., 2018)
	CE2 El uso ADM no genera riesgos de pérdida de información	
	CE3 La obtención de datos externos para el uso de ADM es segura	
	CE4 Los datos de los estudiantes no representan problemas de seguridad y privacidad	
	CE5 La utilización de ADM en otras universidades motiva su adopción	
Intención de Adopción de ADM (IA)	IA1 Me gustaría utilizar ADM	(Ramirez-Anormaliza et al., 2017; Shahbaz et al., 2020)
	IA2 Voy a utilizar ADM en mis labores si tengo la oportunidad	
	IA3 Es importante usar ADM, recomendaría su uso	
	IA4 Tengo la intención de usar ADM	
	IA5 Tengo la intención de usar ADM con frecuencia	

**Nota:** Elaboración propia, se miden en escala Likert

## 1.9 Justificación

Para muchos académicos, las técnicas de ADM tienen la capacidad de transformar la educación humana y los métodos de aprendizaje, y son la fuerza científica para promover el desarrollo de la innovación educativa (Shu et al., 2019).

En las universidades la adopción de ADM se encuentra en una etapa temprana, por lo tanto, es oportuno e importante revisar los factores que influyen en la implementación de esta tecnología en las universidades (Alyoussef & Al-Rahmi, 2022). El desarrollo de este estudio origina un espacio de trascendencia y utilidad práctica para los estudiantes universitarios.

Aboelmaged & Mouakket (2020) evidencian en su estudio que el Modelo de Aceptación de Tecnología (TAM) propuesto por Davis en 1989, se encuentra entre las principales teorías para explicar y predecir la adopción ADM. Este resultado coincide con el de Baig et al. (2019). Por lo tanto, metodológicamente se justifica el uso de TAM en esta investigación.

Múltiples son los beneficios de la adopción de ADM según (Watson (2019), estas tecnologías ayudan innovar a las organizaciones. En este aspecto radica la importancia teórica que proporcionará el trabajo, debido que el resultado será una lista de factores claves para su adopción.

En este trabajo plantea obtener datos sobre los factores que inciden en la adopción y uso de ADM en las universidades, así como comprender los posibles problemas para su implementación, de forma que podamos dar recomendaciones pertinentes a los profesionales que toman decisiones.

Desde el punto de vista del cambio social, la adopción de técnicas ADM incluso mejora la percepción de los usuarios sobre los beneficios que esta tecnología puede ofrecerles (Verma et al., 2018), Lo que justifica realizar esta investigación.

La adopción de Big Data brinda una oportunidad para que las organizaciones superen a los competidores (Baig et al., 2019). Este proceso puede ser complejo pero los réditos que esta tecnología ofrece, justifican realizar este estudio que busca entregar una lista de factores clave para su adopción.

## 1.10 Alcance y limitaciones

La presente investigación tiene como alcance a toda la planta de directivos de una universidad estatal en Ecuador.

La principal limitante de esta investigación podría radicar en que la población objeto de estudio es limitada y bien se podría plantear investigaciones futuras en este mismo contexto, pero que involucre a más instituciones de educación superior.

## **CAPÍTULO II: Marco teórico referencial**

### **2.1. Marco teórico**

#### **2.1.1. Antecedentes Históricos**

Con las computadoras, Internet y la tecnología móvil, diariamente se produce una gran cantidad de datos. En las universidades una de las principales fuentes de datos son los sistemas gestión del aprendizaje (Shorfuzzaman et al., 2019).

La adopción de ADM brinda nuevas oportunidades a las organizaciones para aprovechar la información y obtener una ventaja competitiva y por ende mejora la productividad (ur Rehman et al., 2019).

Islam et al. (2021) concluyen en su estudio que, el rendimiento es más alto cuando la biblioteca académica utiliza herramientas y análisis de big data. Incluso si la biblioteca no procesa big data, tener un alto nivel de experiencia en análisis de big data es esencial para mejorar el rendimiento de la biblioteca.

#### **2.1.2. Antecedentes referenciales**

Al-Rahmi & Alkhalaf (2021) en su estudio encontraron, que las innovaciones y la gestión del conocimiento se comparten en el contexto de ADM para la sostenibilidad de la educación, los mismos que son compatibles con investigaciones anteriores que se han realizado en este campo.

Alyoussef & Al-Rahmi (2022) en su estudio concluyeron que la actitud de los estudiantes hacia el uso y la intención conductual de uso a través de condicione facilitadoras, riesgo percibido, utilidad percibida y facilidad de uso percibida para la adopción de la educación de ADM.

Con ADM de los datos almacenados en la universidad podemos excavar y analizar estos datos en profundidad, y descubrir algún tipo de conexión interna, obtendremos alguna información sugerente beneficiosa (Zhou & Wu, 2022).

Ko et al. (2021) identificaron en su estudio que, la aplicación de ADM a los artículos de noticias ha demostrado su mérito al identificar con éxito los temas que más interesaban al público, aunque también ha demostrado empíricamente que las respuestas gubernamentales y universitarias para combatir el COVID-19 tenían una visibilidad limitada entre los informes de los medios.

## **2.2. Marco legal**

Por el acceso y procesamiento de los datos en la adopción de la ADM, los procedimientos involucrados deben considerar la Ley Orgánica de Protección de Datos Personales, que en su artículo 2 determina: *“La legislación vigente será aplicable al tratamiento de los datos personales contenidos en cualquier tipo de soporte, automatizado o no, así como a las modalidades de uso posterior.”* (Ley Orgánica de Protección de Datos Personales, 2021).

## **2.3. Marco conceptual**

### **2.3.1. Datos masivos**

Se define datos masivos (big data) a un gran volumen de datos (Chamikara et al., 2020). Es un concepto relativamente nuevo, pero el almacenamiento y análisis de datos es una teoría que existe desde hace varios años, incluso desde cuando se hacían registros en papel (Tole, 2013). Los datos masivos por aporte a las organizaciones, son consideradas el combustible para las aplicaciones analíticas de hoy (TechTarget, 2022).

Para Botelho & Bigelow (2022), datos masivos es una combinación de datos estructurados, semiestructurados y no estructurados recopilados por organizaciones que pueden extraerse para obtener información y usarse en proyectos de aprendizaje automático, modelado predictivo y otras aplicaciones de análisis avanzado.

### **2.3.2. Técnicas para evaluar y predecir adopción de tecnología**

La adopción de tecnología (TA) se convirtió en un tema candente por la tercera revolución tecnológica que cambió los métodos de producción y los estilos de vida. TA se define como

un modelo sociológico que describe la adopción o la aceptación de un nuevo producto o una innovación (Xu et al., 2021).

En la revisión de literatura realizada se identificaron cuatro teorías principales para evaluar la adopción de ADM, se las presenta en la **Tabla 2**

**Tabla 2:** Teorías y modelos para evaluar la adopción analítica de datos masivos

Teoría/modelo	Descripción	Fuente
DOI	Teoría de la Difusión de la Innovación	(Rogers, 2003)
TAM	Modelo de aceptación de la tecnología	(Davis, 1985)
TOE	Tecnología–organización–medio ambiente	(Tornatzky & Fleisher, 1990)
TTF	Modelo de ajuste de tareas tecnológicas	(Dishaw & Strong, 1999)

**Nota:** Elaboración propia a partir de (Baig et al., 2019; Xu et al., 2021)

### 2.3.3. Teoría de la Difusión de la Innovación (DOI)

La teoría de la difusión de la innovación es ampliamente utilizada para explicar el proceso de difusión de la innovación. Establece cinco pasos en el proceso de decisión de innovación, estos son conocimiento, persuasión, decisión, implementación y confirmación. Los responsables de la toma de decisiones antes de decir la innovación deben comprender el proceso como tal y luego general el clima favorable en la organización para este proceso (Rogers, 2003).

Rogers (2003) sostiene que hay cinco determinantes importantes que podrían afectar la tasa de adopción, incluida la ventaja relativa, la compatibilidad, la complejidad, la capacidad de prueba y la observabilidad, entre los cuales se cree que los tres primeros son particularmente importantes

### 2.3.4. Modelo de aceptación de la tecnología (TAM)

TAM es una teoría de la disciplina de Sistemas de Información (IS) para explicar, predecir y mejorar la aceptación de la tecnología de la información (TI) por parte del usuario. TAM es la teoría que lidera con su modelo para facilitar la evaluación de diversas implementaciones tecnológicas.

Entre los diversos esfuerzos por comprender el proceso de aceptación de ADM por parte de los usuarios, el TAM es uno de los marcos teóricos más utilizado (Baig et al., 2019). En el campo de la adopción de tecnología, investigaciones recientes dan cuenta de la mayor aplicación del TAM para el efecto (Xu et al., 2021).

La actitud general de un usuario hacia el uso de un sistema hipotético se muestra en función de las estructuras de creencias en el TAM: Utilidad Percibida (PU) (el grado en que un usuario cree que usar un sistema en particular mejorará su rendimiento laboral). y PEOU (Facilidad de uso percibida) (el grado en que una persona cree que usar un sistema específico será fácil) (Elfeky & Elbyaly, 2021).

### **2.3.5. Tecnología–organización–medio ambiente (TOE)**

El marco tecnología-organización-entorno, también conocido como TOE, es un marco teórico que explica la adopción de tecnología en las organizaciones y describe cómo el proceso de adopción e implementación de innovaciones tecnológicas está influenciado por el contexto tecnológico, el contexto organizacional y el contexto ambiental (Tornatzky & Fleisher, 1990).

### **2.3.6. Modelo de ajuste de tareas tecnológicas (TTF)**

El modelo ajuste de la tecnología a la tarea (TTF), implica la coincidencia de las capacidades de la tecnología con las demandas de la tarea. La TTF postula que la tecnología de la información se utilizará si, y solo si, las funciones disponibles para el usuario soportan (se ajustan) a las actividades del usuario. Los usuarios racionales y experimentados elegirán aquellas herramientas y métodos que les permitan completar la tarea con el mayor beneficio neto. No se utilizará la tecnología de la información que no ofrezca suficiente ventaja (Dishaw & Strong, 1999).

## **CAPÍTULO III: Diseño metodológico**

### **3.1. Tipo y diseño de investigación**

La presente investigación por la finalidad será aplicada; ya que los resultados de la misma estarán en beneficio de los estudiantes universitarios, al identificar los factores que condicionan la adopción de una tecnología como lo es la ADM por parte de los directivos.

Este estudio por su objetivo gnoseológico o alcance es correlacional; dado que asocia las variables propuestas, tiene un nivel de predicción de los factores que puede permitir la adopción de ADM entre los directivos y mide la intensidad de la relación de las variables propuestas en el modelo de investigación.

Por contexto, el presente estudio es de campo, ya que se encuestará a los directivos en sus ambientes diarios de trabajo, pues recibirán un enlace al formulario y no deberán trasladarse a laboratorio alguno para completarlo.

Atendiendo el control de variables, la presente investigación es no experimental; debido a que no se manipulará ni tendrá control de ninguna variable durante el desarrollo.

Por orientación temporal, este estudio es transversal; ya que los datos serán tomados en un momento específico a los estudiantes y no se va a evaluar todo un semestre o periodo académico.

### **3.2. La población y la muestra**

#### **3.2.1. Características de la población**

La población que formó parte de este estudio fueron todos los directivos de la Universidad Estatal de Milagro; conformada por Rector, Vicerrectores, Decanos, directores de Carrera, directores de Unidades Organizacionales y Coordinadores de procesos sustantivos.

#### **3.2.2. Delimitación de la población**

La población de estudio la formaron los directivos de la Universidad Estatal de Milagro, los mismos que según reporte de la distribución de trabajo del período de la investigación está estructurada de la siguiente forma:

- Directivos de procesos estratégicos, sustantivos y adjetivos de apoyo académico 73.
- Directivos de procesos adjetivos de apoyo y asesoría 17.

Por el número de elementos que conforman la población (90), no se calculó muestra, se trabajó con toda la población.

### **3.3. Los métodos y las técnicas**

#### **3.3.1. Métodos teóricos**

El método que se utilizará es el inductivo, ya que se va a extraer conclusiones a partir de medición de las respuestas obtenidas de los estudiantes universitarios para luego generalizarlas y se basará en las probabilidades.

#### **3.3.2. Métodos empíricos**

La observación de la realidad o del objeto de estudio se valdrá de la encuesta, para lo cual se ha diseñado un instrumento basado en estudios previos.

#### **3.3.3. Instrumentos**

Se aplicó un cuestionario a todos los directivos de la Universidad Estatal de Milagro. El instrumento contempló indicadores medidos utilizando una escala tipo Likert de seis puntos que van desde "Muy en desacuerdo" a "Muy de acuerdo". Los ítems del cuestionario para cuantificar la adopción de ADM en las universidades fueron adaptados de estudios previos, se los presentaron en la operacionalización de variables en la **Tabla 3**.

#### **3.3.4. Técnicas**

En los estudios revisados se identificó, que la técnica más utilizada en investigaciones de este tipo fue el modelo de ecuaciones estructurales (Structural Equation Modeling, SEM), en ésta al referirse a variables latentes se refiere indistintamente a los términos de constructo o variable latente, son variables que no son observadas directamente, son medidas a través de variables indicadoras o indicadores (ítems), que son observables directamente (Al-Maatouk et al., 2020).

**Tabla 3:** Variables e indicadores

Variable	Indicadores	Fuente
Contexto Tecnológico (CT)	CT1 ADM mejora la calidad del trabajo	(Maroufkhani et al., 2020)
	CT2 ADM mejora el servicio a los estudiantes	
	CT3 Aprender a utilizar ADM es fácil para los empleados	
	CT4 ADM es fácil de mantener	
	CT5 Subcontratar ADM genera riesgo de dependencia del proveedor	
	CT6 Mi organización cuenta con computadoras para utilizar ADM	
Contexto Organizacional (CO)	CO1 La infraestructura organizacional posibilita la implementación de ADM	(Sam & Chatwin, 2018)
	CO2 Las autoridades de la universidad apoyan el uso de ADM	
	CO3 El personal de la universidad posee experiencia y habilidades para el uso de ADM	
	CO4 La universidad posee capacidad financiera para invertir en el uso de ADM	
	CO5 La estrategia de la universidad es congruente con el uso de ADM	
Contexto del entorno (CE)	CE1 Las instituciones de control y acreditación alientan el uso de ADM	(Sun et al., 2018)
	CE2 El uso ADM no genera riesgos de pérdida de información	
	CE3 La obtención de datos externos para el uso de ADM es segura	
	CE4 Los datos de los estudiantes no representan problemas de seguridad y privacidad	
	CE5 La utilización de ADM en otras universidades motiva su adopción	
Intención de Adopción de ADM (IA)	IA1 Me gustaría utilizar ADM	(Ramirez-Anormaliza et al., 2017; Shahbaz et al., 2020)
	IA2 Voy a utilizar ADM en mis labores si tengo la oportunidad	
	IA3 Es importante usar ADM, recomendaría su uso	
	IA4 Tengo la intención de usar ADM	
	IA5 Tengo la intención de usar ADM con frecuencia	

**Nota:** Elaboración propia

El modelo de regresión, el análisis del remitente y el análisis factorial forman la base de SEM. El modelo de regresión, que se basa en la regresión lineal, calcula los pesos de la regresión utilizando un coeficiente de correlación y la regla de los cuadrados mínimos. Para proporcionar un indicador de la relación entre dos variables, Karl Pearson desarrolló una fórmula para el coeficiente de correlación en 1896. (Schumacker & Lomax, 2010).

Los SEM son ampliamente utilizados en administración, psicología e innovación, por la facilidad de poder trabajar con varias variables y sus relaciones en un mismo estudio (Cepeda Carrión & Roldan Salgueiro, 2004). De los dos enfoques para cálculo de los parámetros en SEM y los criterios para la aplicación de cada uno de ellos, PLS es el que mejor se ajusta para predecir aceptación; por lo tanto, es la mejor opción para esta investigación.

Para la modelización de ecuaciones estructurales con enfoque PLS se debe tener en cuenta los aspectos citados en la **Tabla 4**.

**Tabla 4:** Consideraciones modelamiento SEM-PLS

Consideraciones	Fuente
Se puede usar para modelar la investigación que involucra variables de rasgos conductuales latentes.	(Höök & Löwgren, 2012)
Para estudios de factores de éxito, PLS es una herramienta estadística preferida.	(Albers, 2010)
PLS es una familia de modelos de mínimos cuadrado que replica y amplía el análisis de componentes principales y el análisis de correlación canónica.	(Wold, 1974)
Concebido como un método totalmente legal capaz de gestionar modelos factoriales y modelos generados por ordenador para la medición en obra.	(Dijkstra & Henseler, 2015)

**Nota:** Elaboración propia

### 3.3.5. Modelo de ecuaciones estructurales enfoque PLS

Para realizar la evaluación de modelos de ecuaciones estructurales con enfoque en mínimos cuadrados parciales o PLS, se debe primero realizar la valoración de modelo global, luego la valoración del modelo de medidas y finalmente la valoración del modelo estructural. Para el efecto, los modelos de medidas son cada una de las variables latentes del estudio relacionadas con sus respectivos indicadores; el modelo estructural es la relación entre cada una de las variables latentes (son la hipótesis del modelo), y, la evaluación del modelo global consiste en revisar índices que permiten identificar si los datos se ajustan o no al modelo planteado.

La bondad de ajuste global del modelo determinará si puede o no avanzar con el estudio y que las conclusiones serán válidas (Henseler et al., 2016). Para evaluar la bondad de ajuste global del modelo se sugieren los índices expuestos en la **Tabla 5**.

### 6.4.5. Valoración del modelo de medida

La valoración del modelo de medida, también conocido como modelo externo se realiza a través del análisis de la fiabilidad individual de los indicadores, el análisis de fiabilidad de constructo y el análisis de validez convergente. En la

**Tabla 6** se detallan los índices y criterios.

**Tabla 5:** Índices de ajuste global del modelo

<b>Índice</b>	<b>Criterio</b>	<b>Fuente</b>
<i>Standardized root mean square residual</i> (SRMR), mide la diferencia entre la matriz de correlaciones observada y la matriz de correlaciones implicada por el modelo.	SRMR más bajo, mejor ajuste, buen ajuste cuando SRMR < 0.08	(Hu & Bentler, 1998)
<i>Normed Fit Index (NFI)</i> o índice Bentler & Bonett.	Cuanto más cerca de 1, mejor. Valores por encima de 0,9 representan un ajuste aceptable.	
root mean square error correlation (RMS Theta), también se utilizar para evaluar el ajuste del modelo	Valores por debajo de 0.12, se pueden considerar como buen ajuste	

**Nota:** Elaboración propia

#### 6.4.6. Valoración del modelo estructural

Al momento de evaluar el modelo interno o modelo estructural, se verifica si existen problemas de colinealidad, se valoran los coeficientes de ruta o senderos, se analiza el  $R^2$  o coeficiente de determinación, se evalúan los tamaños de los efectos y se evalúa la relevancia predictiva del modelo. Los índices y criterios que se presentan en la

Tabla 7.

Tabla 6: Índices para la valoración del modelo de medida

Índice	Criterio	Fuente
<i>Fiabilidad individual de indicadores.</i> Se examinan las cargas factoriales ( $\lambda$ ) o correlaciones simples, de las medidas o indicadores con su respectivo constructo	$\lambda \geq 0.707$ Se aceptan. menor que 0.4, deberían ser eliminados	(Carmines & Zeller, 1979), (Hair et al., 2011).
<i>Fiabilidad del constructo.</i> Determina si los ítems que miden un constructo son similares en sus puntuaciones. Se utiliza: Coeficiente alfa de Cronbach ( $\alpha$ ); Fiabilidad compuesta ( $\rho_A$ ).	0.7 como mínimo en etapas tempranas y un más estricto 0.8 o 0.9	(Garson, 2016).
<i>Validez convergente</i> Un conjunto de indicadores representa un único constructo subyacente. Se usa la varianza extraída media (average variance extracted - AVE).	AVE $\geq 0.50$	(Henseler et al., 2009). (Fornell & Larcker, 1981).
<i>Validez discriminante</i> La medida en que un constructo dado es diferente de otros constructos. Se utiliza El análisis de cargas cruzadas y criterio de Fornell y Larcker (1981).	Ningún ítem debería cargar más fuertemente sobre otro constructo que sobre aquel que trate de medir  La cantidad de varianza que un constructo captura de sus indicadores (AVE) debería ser mayor que la varianza que dicho constructo comparte con otros constructos en el modelo	(Barclay et al., 1995). (Gefen & Straub, 2005).  (Fornell & Larcker, 1981)

**Nota:** Elaboración propia

**Tabla 7:** Índices para la valoración del modelo estructural

Índice	Criterio	Fuente
<i>Problemas de colinealidad.</i> Evitar la presencia de multicolinealidad entre las variables antecedentes de cada uno de los constructos endógenos.	Indicios de multicolinealidad cuando $FIV > 5$ , niveles de tolerancia $< 0.20$ .	(Garson, 2016),
<i>Evaluación de los coeficientes path.</i> Muestran las relaciones del modelo estructural. Se analizará el signo algebraico, la magnitud y la significación estadística (por Bootstrapping, técnica de remuestreo no paramétrica).	Mayores valores absolutos denotan mayores relaciones (predictivas) entre constructos; cuanto más cercano a cero es el valor, más débil es la relación.	(Hair et al., 2011).
<i>Coefficiente de determinación</i> El ( $R^2$ ) es medida de poder predictivo, en tanto que indica la cantidad de varianza de un constructo que es explicada por las variables predictoras de dicho constructo endógeno en el modelo (entre 0 a 1).	mínimo $\geq 0.10$ 0.67 es sustancial, 0.33 es moderado y 0.19 es débil En marketing 0.75 es sustancial, 0.5 es moderado y 0.25 se puede considera débil	(Falk & Miller, 1992) (Chin, 1998b) (Hair, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, 2014)
<i>Los tamaños de los efectos</i> ( $f^2$ ) valora el grado con el que un constructo exógeno contribuye a explicar un determinado constructo endógeno en términos de $R^2$	$0.02 \leq f^2 < 0.15$ , es un efecto pequeño; $0.15 \leq f^2 < 0.35$ , es un efecto moderado y $f^2 \geq 0.35$ es un efecto grande. Un modelo anidado debería ser rechazado si no produce un $f^2$ significativo.	(Cohen, 1988).
<i>Relevancia predictiva</i> Error Absoluto Medio (MAE) y Error Cuadrático Medio (RMSE)	Si el error de predicción es muy sesgado, el MAE es una métrica más adecuada	(Shmueli et al., 2019)
	Al comparar los valores RMSE (o MAE) con los valores LM, se aplican 1. Si todos los indicadores en el análisis PLS-SEM tienen valores RMSE (o MAE) más bajos en comparación con el punto de referencia LM ingenuo, el modelo tiene un alto poder predictivo. 2. Si la mayoría (o el mismo número) de indicadores en el análisis PLS-SEM arroja errores de predicción más pequeños en comparación con el LM, esto indica un poder predictivo medio. 3. Si una minoría de los indicadores del constructo dependiente produce errores de predicción PLS-SEM más bajos en comparación con el punto de referencia LM ingenuo, esto indica que el modelo tiene un poder predictivo bajo. 4. Si el análisis PLS-SEM (en comparación con el LM) arroja errores de predicción más bajos en términos de RMSE (o MAE) para ninguno de los indicadores, esto indica que el modelo carece de poder predictivo.	

**Nota:** Elaboración propia

### 3.3.6. Consideraciones éticas

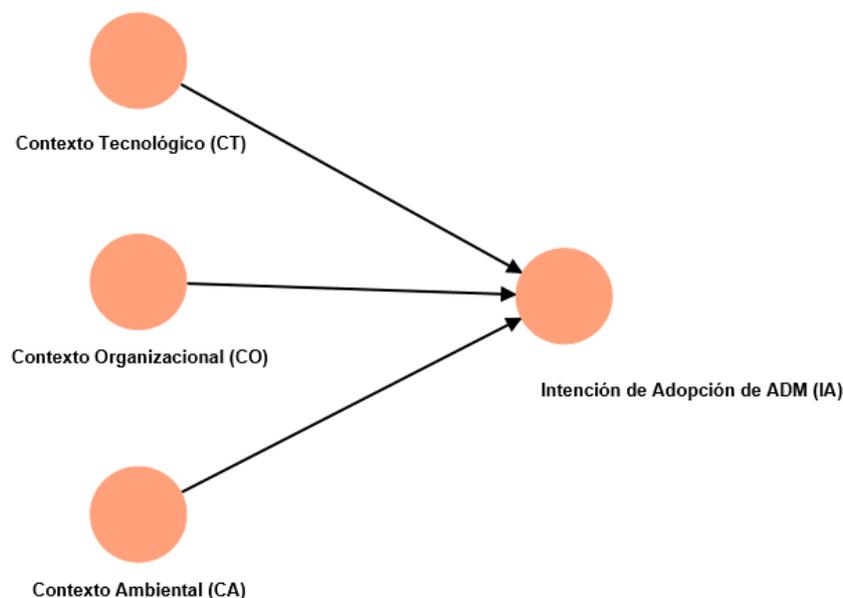
Con la finalidad de preservar la identidad de los encuestados y en aplicación del marco legal definido en esta investigación, al momento de realizar la recolección de datos, no se solicitarán datos personales a los participantes del estudio.

Para la realización de esta investigación se solicitó la autorización a las autoridades de la institución de educación superior involucrada, la participación fue voluntaria y sus respuestas se guardaron de manera anónima.

### 3.4. Procesamiento estadístico de la información.

Los datos del estudio se obtuvieron con la ayuda de una herramienta web de pago. Esta encuesta fue anónima y enviada a los encuestados por correo electrónico con la referencia del enlace.

Para procesar los datos y analizar los resultados, se utilizó modelos de ecuaciones estructurales con un enfoque de mínimos cuadrados parciales (PLS). Para lo cual se utilizó el paquete de SEMinR en el software R, para la evaluación de ajuste global del modelo se utilizó el software SmartPLS versión 4.0 estudiante, en la evaluación de la relevancia predictiva del modelo propuesto se utilizó el primer software citado. Las hipótesis, así como el marco de este estudio se presentan en la **Figura 1**.



**Figura 1:** Modelo de investigación

## CAPÍTULO IV: Análisis e interpretación de resultados

### 3.5. Introducción

Los datos fueron recolectados de la forma expuesta en metodología en el capítulo anterior. De los 90 directivos consultados, 67 completaron satisfactoriamente el cuestionario lo que equivale una tasa de respuesta del 74%. Para tener una visión de las respuestas recibidas, en la **Tabla 8** se puede apreciar un resumen.

**Tabla 8:** Resumen de respuestas recibidas

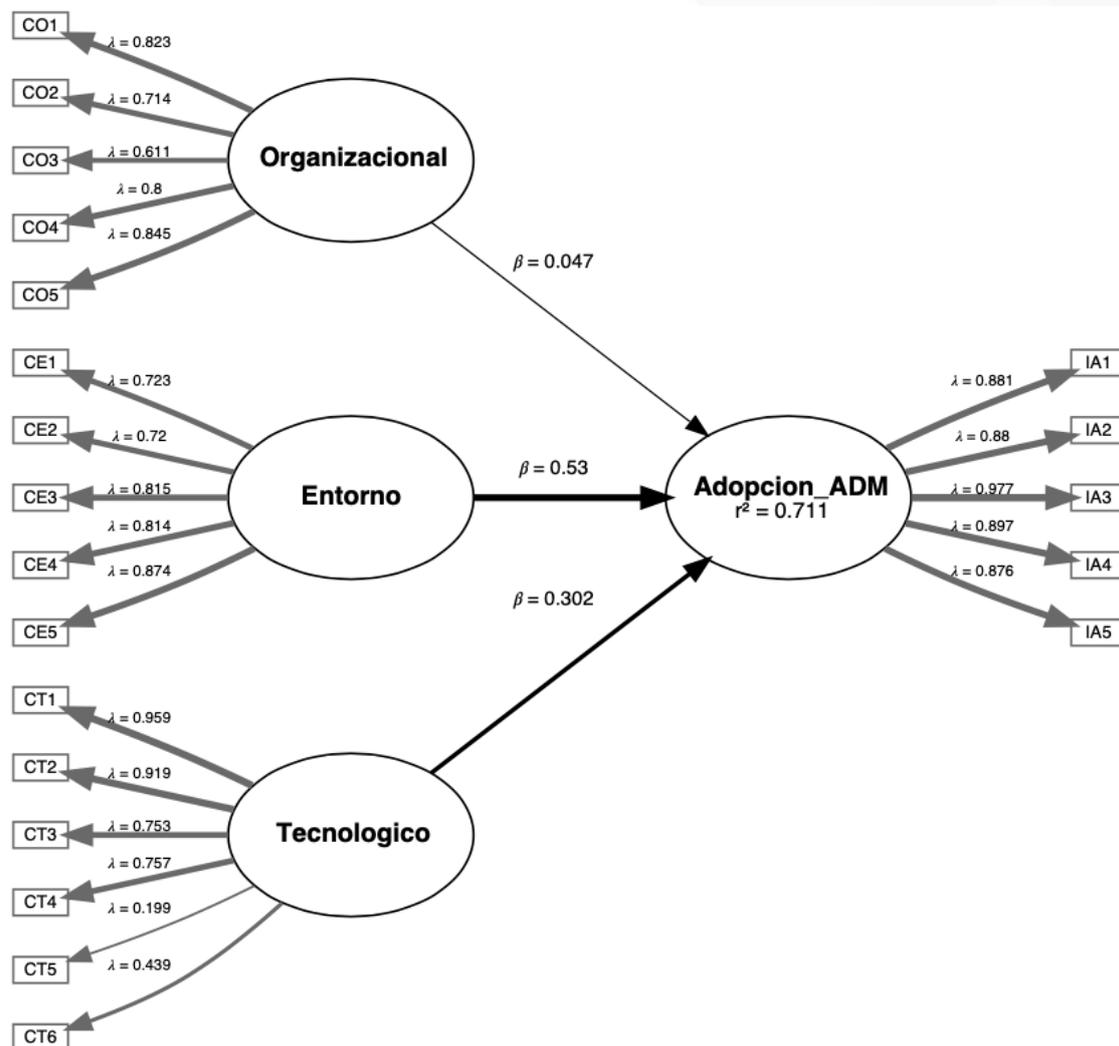
No.	Ítem	Media	Mediana	Valor mínimo	Valor máximo	Desviación estándar	Exceso de curtosis	Asimetría
1	CT1	5.463	6	1	6	0.974	10.238	-2.519
2	CT2	5.478	6	1	6	0.911	11.095	-2.542
3	CT3	4.612	5	1	6	1.128	4.072	-1.048
4	CT4	4.836	5	1	6	1.123	5.082	-1.421
5	CT5	4.269	5	1	6	1.513	2.739	-0.754
6	CT6	4.687	5	1	6	1.328	3.862	-1.209
7	CO1	5.104	5	1	6	1.089	5.319	-1.485
8	CO2	5.299	6	1	6	1.000	7.937	-1.997
9	CO3	4.134	4	1	6	1.100	3.487	-0.406
10	CO4	4.731	5	1	6	1.149	3.639	-0.910
11	CO5	5.075	5	1	6	0.926	7.165	-1.531
12	CE1	4.910	5	1	6	1.190	4.880	-1.348
13	CE2	5.015	5	1	6	1.161	5.811	-1.609
14	CE3	5.000	5	1	6	1.015	6.028	-1.489
15	CE4	5.015	5	1	6	1.066	5.113	-1.316
16	CE5	5.179	5	1	6	1.014	6.978	-1.770
17	IA1	5.463	6	1	6	0.910	10.433	-2.380
18	IA2	5.433	6	1	6	0.925	10.050	-2.349
19	IA3	5.403	6	1	6	0.889	10.703	-2.315
20	IA4	5.403	6	1	6	0.906	10.513	-2.360
21	IA5	5.373	6	1	6	0.951	8.991	-2.189

**Nota:** Elaboración Propia con paquete SEMinR en R

### 3.6. Revisión preliminar del modelo

En esta evaluación preliminar del modelo, considerando lo definido en la metodología seguida, se verifica los índices de ajuste global del modelo y la fiabilidad individual de los indicadores, se identificó que dos ítems de la variable latente Contexto Tecnológico tenían

cargas factoriales por debajo de 0.707, por lo tanto, los ítems CT5 y CT6 fueron eliminados del modelo. Lo expuesto en este apartado se puede corroborar en la **Figura 2**.



**Figura 2:** Evaluación preliminar del modelo (Calculado con paquete SEMinR en R)

### 3.7. Valoración global del modelo

Se identificó que el modelo se ajusta a los datos, esto lo confirman los índices. El SRMR es menor que 0.08 (0.075) y el NFI tiende a 1 (0.744). Para esta valoración se utilizó el software SmartPLS versión 4.0.

### 3.8. Valoración del modelo de medida

#### 3.8.1. Fiabilidad individual de los indicadores

Se revisaron las cargas factoriales y para todos los indicadores, estas son mayores a 0.707, en la **Tabla 9** podemos ver las cargas factoriales de los indicadores.

**Tabla 9:** Fiabilidad individual de indicadores

Constructos e indicadores	Media	Desviación estándar	Carga factorial
<i>Contexto del entorno (CE)</i>			
CE1	0.799	0.069	0.806
CE2	0.852	0.049	0.859
CE3	0.858	0.069	0.870
CE4	0.783	0.090	0.796
CE5	0.847	0.066	0.856
<i>Contexto organizacional (CO)</i>			
CO1	0.824	0.074	0.838
CO2	0.821	0.096	0.851
CO3	0.801	0.051	0.803
CO4	0.776	0.060	0.768
CO5	0.813	0.076	0.831
<i>Contexto tecnológico (CT)</i>			
CT1	0.922	0.035	0.931
CT2	0.881	0.055	0.895
CT3	0.809	0.079	0.817
CT4	0.850	0.042	0.846
<i>Intención de adopción (IA)</i>			
IA1	0.908	0.049	0.921
IA2	0.896	0.052	0.906
IA3	0.934	0.030	0.940
IA4	0.942	0.033	0.950
IA5	0.886	0.064	0.898

**Nota:** Elaboración propia con el uso de SmartPLS versión 4.0

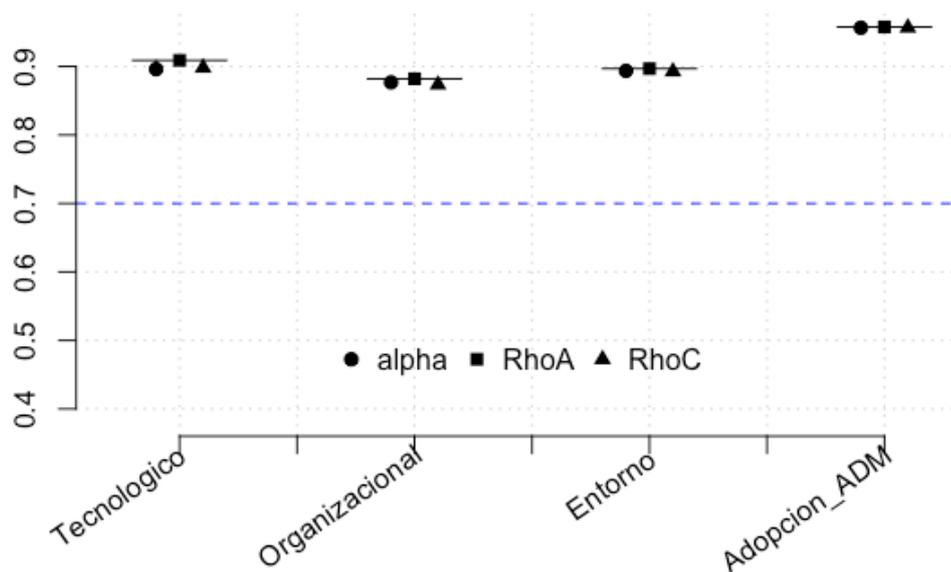
#### 3.8.2. Fiabilidad del constructo

La consistencia interna de los indicadores que miden los constructos se evaluó por medio del Alfa de Cronbach ( $\alpha$ ) y Fiabilidad Compuesta ( $\rho_A$ ). Todos los constructos satisfacen el requerimiento de la fiabilidad de constructo ya que los dos índices evaluados obtuvieron valores mayores que 0.8, como se aprecia en la **Tabla 10**. También se puede apreciar la fiabilidad del constructo en la **Figura 3**.

**Tabla 10:** Fiabilidad y validez de constructo

Constructos	$\alpha$	$\rho_A$
CE	0.894	0.897
CO	0.877	0.882
CT	0.896	0.909
IA	0.957	0.958

**Nota:** Elaboración propia (Paquere SEMinR)



**Figura 3:** Fiabilidad de constructo (Dibujado con SEMinR)

### 3.8.3. Validez Convergente

La validez convergente se evaluó mediante la varianza extraída media (average variance extracted - AVE). Como se puede ver en la **Tabla 11**, todas las variables latentes alcanzaron la validez convergente ya que sus medidas AVE superaron el nivel mínimo de 0.50.

**Tabla 11:** Validez convergente

Constructos	AVE
CE	0.894
CO	0.877
CT	0.896
IA	0.957

**Nota:** Elaboración Propia (SmartPLS versión 4.0)

### 3.8.4. Validez Discriminante

La validez discriminante se evaluó por medio el análisis de cargas cruzadas y el criterio de Fornell y Larcker (1981). En las cargas cruzadas, como se aprecia en la **Tabla 13** todos los constructos alcanzan la validez discriminante, pues ningún ítem carga más fuertemente sobre

otro constructo que sobre aquel constructo que trata de medir; a su vez, cada constructo carga más sobre sus indicadores asignados que sobre otros ítems.

Por el criterio de Fornell-Larcker, en la **Tabla 12** se puede apreciar que los elementos en la diagonal (en negrita) son la raíz cuadrada de la varianza compartida entre el constructo y sus medidas (AVE), los elementos fuera de la diagonal son las correlaciones entre constructos. Todos constructos alcanzan validez discriminante ya que, la raíz cuadrada del AVE de los constructos es mayor que la correlación que estos tiene con los otros constructos.

**Tabla 12:** Validez discriminante - Fornell-Larcker

Constructos	CE	CO	CT	AI
CE	<b>0.838</b>			
CO	0.740	<b>0.819</b>		
CT	0.753	0.729	<b>0.873</b>	
IA	0.764	0.683	0.756	<b>0.923</b>

**Nota:** Elaboración Propia (SmartPLS versión 4.0)

**Tabla 13:** Cargas cruzadas del modelo

Indicadores	CE	CO	CT	AI
CE1	<b>0.806</b>	0.732	0.605	0.583
CE2	<b>0.859</b>	0.545	0.677	0.581
CE3	<b>0.870</b>	0.568	0.670	0.657
CE4	<b>0.796</b>	0.585	0.537	0.657
CE5	<b>0.856</b>	0.670	0.665	0.705
CO1	0.637	<b>0.838</b>	0.678	0.599
CO2	0.505	<b>0.851</b>	0.552	0.519
CO3	0.622	<b>0.803</b>	0.526	0.444
CO4	0.636	<b>0.768</b>	0.603	0.582
CO5	0.620	<b>0.831</b>	0.601	0.614
CT1	0.675	0.622	<b>0.931</b>	0.742
CT2	0.661	0.608	<b>0.895</b>	0.710
CT3	0.674	0.714	<b>0.817</b>	0.582
CT4	0.628	0.625	<b>0.846</b>	0.585
IA1	0.696	0.589	0.687	<b>0.921</b>
IA2	0.673	0.624	0.692	<b>0.906</b>
IA3	0.774	0.692	0.721	<b>0.940</b>
IA4	0.705	0.644	0.683	<b>0.950</b>
IA5	0.674	0.598	0.705	<b>0.898</b>

**Nota:** Elaboración propia (SmartPLS versión 4.0)

### 3.9. Valoración del modelo estructural - hipótesis

#### 3.9.1. Valoración de la colinealidad

Se revisaron los valores FIV internos (estructural) para evaluar problemas de colinealidad. Se determinó que no hay problemas de colinealidad, pues todos los FIV resultaron menores a 5, tal como se observa en la **Tabla 14**.

**Tabla 14:** Valores FIV del modelo estructural

Constructo	CE	CO	CT	IA
CE				2.814
CO				2.603
CT				2.721
IA				

**Nota:** Elaboración propia (Paquete SEMinR)

#### 3.9.2. Evaluación de los coeficientes de senderos (hipótesis)

En la **Tabla 15** se puede apreciar la evaluación del signo algebraico, magnitud y significación estadística de los coeficientes de senderos. Para determinar la significación estadística se ejecutó el procedimiento de bootstrapping para  $n = 5000$  submuestras.

**Tabla 15:** Coeficientes de senderos

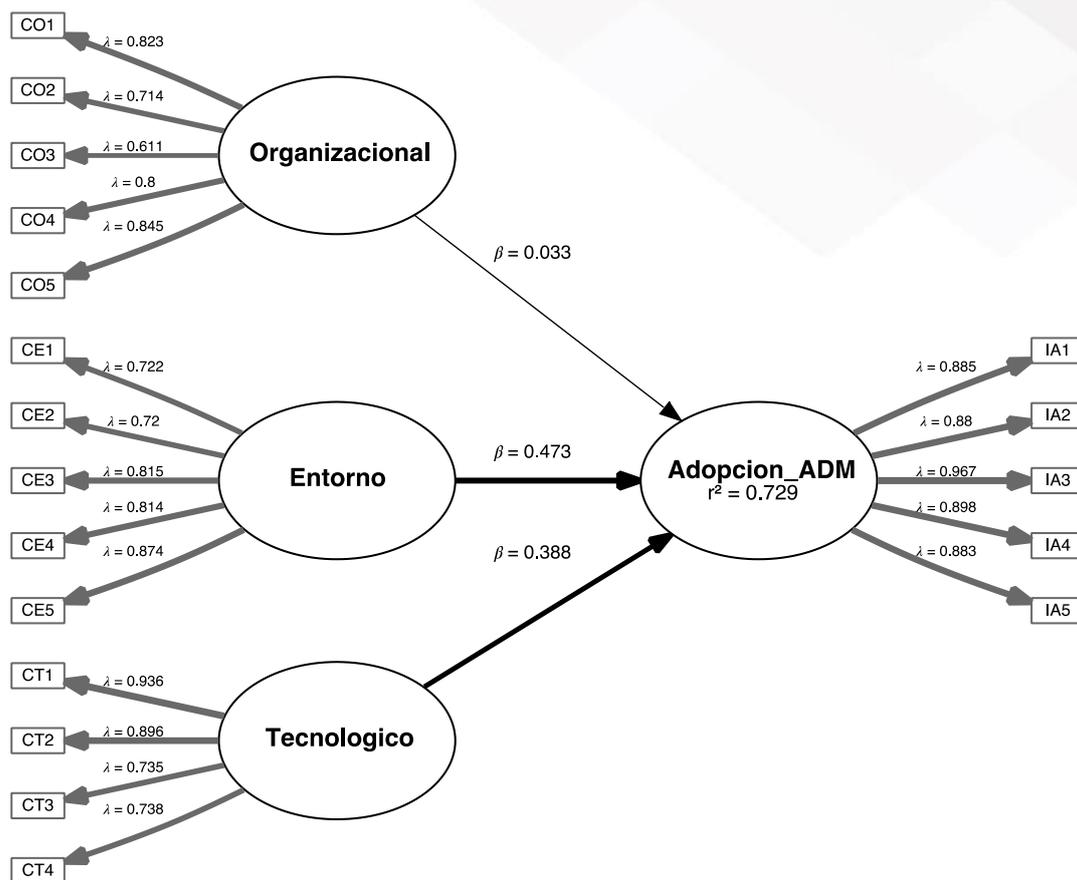
Constructos	Muestra Original(O)	Media de la Muestra (M)	Desviación estándar (STDEV)	Estadístico T
CE → IA	0.473	0.417	4.322	0.110
CO → IA	0.033	0.096	4.735	0.007
CT → IA	0.388	0.365	0.622	0.624

**Nota:** Elaboración propia (Calculado con Paquete SEMinR)

Se aprecia que las relaciones CE → IA y CT → IA, resultaron estadísticamente significativas; y, la relación → CO → IA resultó no significativa. Lo expuesto también se puede ver en la **Figura 4**.

#### 3.9.3. Valoración del coeficiente de determinación

La evaluación del modelo estructural también se realizó mediante el coeficiente de determinación R cuadrado (R<sup>2</sup>) cuyo valor fue de 0.729, que se podría considerar como sustancial (Chin, 1998b). Esto se aprecia en la **Figura 4**.



**Figura 4:** Evaluación del modelo (Dibujado con SEMinR)

### 3.9.4. Valoración de los tamaños de los efectos

Para evaluar el grado con el que un constructo exógeno contribuye a explicar un determinado constructo endógeno en términos de  $R^2$ , se revisó el  $f^2$ . Los valores de  $f^2$  se presentan en la **Tabla 16**. Se aprecia que CE y CT sobre IA, tienen un efecto moderado, ya que  $0.15 \leq f^2 < 0.35$ . Mientras que CO sobre IA tiene un efecto pequeño, debido a que  $0.02 \leq f^2 < 0.15$ .

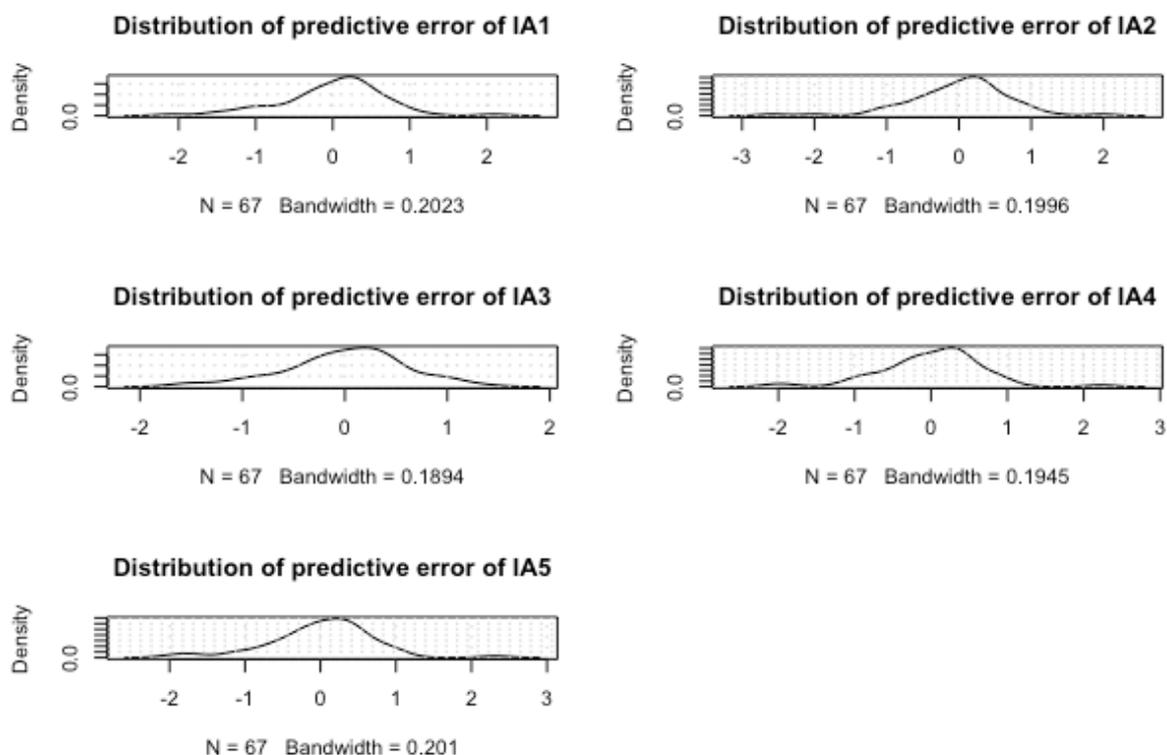
**Tabla 16:** Tamaños de los efectos

Constructos	CE	CO	CT	IA
CE				0.193
CO				0.001
CT				0.144
IA				

**Fuente:** Elaboración propia (SEMinR)

### 3.9.5. Valoración de la relevancia predictiva

La relevancia predictiva se evaluó mediante la ejecución del procedimiento  $PLS_{predict}$ , por medio del paquete SEMinR en el software R, para lo cual se ejecutó la función  $predict\_pls()$ . Se ejecutó el procedimiento  $PLS_{predict}$  con  $k=10$  pliegues ( $noFolds = 10$ ) y 10 repeticiones ( $reps = 10$ ). Además, se utilizó el enfoque de antecedentes directos ( $technique = predict\_DA$ ). Luego se evaluó la distribución del error de predicción, mediante la función  $plot()$  especificando los indicadores de interés, para el efecto los del constructo endógeno (IA1, IA2, IA3, IA4 y IA5). Este resultado se puede ver en la **Figura 5**.



**Figura 5:** Distribución de los errores de predicción (con uso de  $predict\_pls()$  y  $plot()$ )

Como los valores brutos de los estadísticos de predicción no tienen mucho significado. Se deben comparar los valores RMSE (o MAE) con un modelo de regresión lineal (LM) ingenuo ((Danks & Ray, 2018) & Ray, 2018). Para el efecto los valores de referencia de LM se obtienen ejecutando una regresión lineal de cada uno de los indicadores del constructo dependiente sobre los indicadores de los constructos exógenos en el modelo de sendero PLS.

Los resultados de la **Figura 5** evidencia que todas las gráficas tiene una cola y esta es ligeramente sesgada; por lo tanto, que la distribución de los errores de predicción es bastante simétrica y se utilizó el RMSE para determinar qué tan predictivo es el modelo.

Para la evaluación de la relevancia predictiva del modelo, la **Tabla 17** se resumen los estadísticos calculados.

**Tabla 17:** Resumen de los estadísticos predictivos

<i>Métricas en la muestra de PLS:</i>					
	IA1	IA2	IA3	IA4	IA5
RMSE	0.602	0.621	0.520	0.595	0.635
MAE	0.464	0.464	0.415	0.454	0.472
<i>Métricas fuera de la muestra de PLS:</i>					
	IA1	IA2	IA3	IA4	IA5
RMSE	0.684	0.710	0.592	0.667	0.697
MAE	0.512	0.520	0.460	0.498	0.515
<i>Métricas en la muestra de LM:</i>					
	IA1	IA2	IA3	IA4	IA5
RMSE	0.504	0.539	0.457	0.506	0.552
MAE	0.398	0.410	0.355	0.391	0.424
<i>Métricas fuera de la muestra de LM:</i>					
	IA1	IA2	IA3	IA4	IA5
RMSE	0.742	0.831	0.732	0.772	0.864
MAE	0.581	0.618	0.534	0.566	0.632

**Fuente:** Elaboración propia (Calculado con SEMinR)

Una vez determinado que el estadístico que se debe comparar para evaluar la relevancia predictiva del modelo es RMSE, se procedió a comparar las métricas fuera de la muestra de PLS y LM, para una mejor comprensión se desarrolló la **Tabla 18**. Como se aprecia todos los indicadores en el análisis PLS-SEM tienen valores RMSE más bajos en comparación con el punto de referencia LM ingenuo, por ello se concluye que el modelo tiene un alto poder predictivo.

**Tabla 18:** Comparación de RMSE (PLS y LM)

Indicador	RMSE		PLS < LM
	PLS	LM	
IA1	0.684	0.742	Si
IA2	0.710	0.831	Si
IA3	0.592	0.732	Si
IA4	0.667	0.772	Si
IA5	0.697	0.864	Si

**Fuente:** Elaboración propia (Calculado a partir de **Tabla 17**)

## CAPÍTULO V: Conclusiones, Discusión y Recomendaciones

### 5.1 Conclusiones

- El contexto tecnológico y el contexto del entorno son factores claves para la adopción de Analítica de Datos Masivos entre los directivos universitarios del Ecuador.
- El conocimiento de las bondades de la Analítica de Datos Masivos en la mejora la calidad del trabajo entre los funcionarios es importante; la planta de directivos y el personal de soporte deben conocer del uso y los beneficios de estas herramientas, para de esta manera garantizar en gran medida la ejecución de proyectos de este tipo.
- La aplicación la analítica de datos masivos en la universidad ayudará a los directivos a tomar mejores decisiones, al personal operativo mejorar su trabajo y a los estudiantes recibir más y mejores servicios.
- Contar con una planta de empleados y directivos universitarios capacitados en el uso y desarrollo de soluciones basadas en Analítica de datos masivos hará que, al momento de implementarlas, éstas sean percibidas como fáciles de utilizar y por ende garantizar el éxito de esas soluciones en la universidad.
- Mantener al personal de TIC actualizado en el desarrollo de soluciones basadas en Analítica de datos Masivos, permitirá que puedan desarrollar y dar mantenimiento de manera satisfactoria a este tipo de aplicaciones, de esta manera no tener que depender de proveedores externos.
- Las instituciones de control y acreditación del sistema de educación superior a menudo requieren grandes cantidades de datos e informes lo cual constituye una motivación para que los directivos tomen la decisión de implementar el uso de ADM.
- La utilización ADM pudiera hacer percibir un riesgo de pérdida de información sensible, con los controles del caso esto no debe suponer un problema para los usuarios.
- La obtención de datos externos para el uso de ADM se debe hacer con la confiabilidad y seguridad del caso, para ello existen los medios tecnológicos y de cooperación con organizaciones externas.
- Evidenciar la utilización de ADM en otras universidades, es otro factor motivador para utilizar este tipo de herramientas en la institución. Esto dentro del marco de Innovación constante bajo el cual deben actuar las instituciones y en especial las de educación superior.

## 5.2 Discusión

El presente estudio encontró que el Contexto Tecnológico (CT) y el Contexto del Entorno influyen positivamente en la adopción de la Analítica de Datos Masivos entre los directivos de las universidades en Ecuador, lo que coincide con estudios previos de este tipo; mientras que el Contexto Organizacional no.

Los hallazgos antes citados, se pueden atribuir a los beneficios que se obtienen en el desempeño de sus trabajos con la utilización de este tipo de herramientas los directivos de las universidades y a los múltiples servicios que se pueden ofrecer a los estudiantes con la utilización de las tecnologías objeto de estudio.

El uso de big data en las universidades puede aportar una serie de beneficios significativos que pueden mejorar la eficiencia operativa, la toma de decisiones y la experiencia educativa en general.

Una limitante al presente estudio se puede considera el hecho de haber sido desarrollado en una sola universidad, a futuro podría ampliar la muestra.

## 5.3 Recomendaciones

- Fortalecer el contexto tecnológico y el contexto del entorno organizacional para garantizar el éxito de la implementación de ADM en las universidades.
- Capacitar a los empleados y directivos en el uso de Analítica de datos Masivos en las universidades. De manera especial al personal de TIC pues serán los responsables del desarrollo y mantenimiento de estas aplicaciones.
- Implementar los controles de seguridad y privacidad pertinentes al momento de utilizar soluciones basadas en ADM.
- Implementar los mecanismos tecnológicos y de cooperación necesarios para poder integrar de manera segura datos externos a las soluciones de ADM en la universidad.
- Implementar ADM en las universidades, atendiendo los factores claves identificados en este estudio, con ello se podrán tener beneficios como:
  - Seguridad en el campus universitario: Mediante el análisis de datos de seguridad y el uso de sensores inteligentes, las universidades pueden mejorar la seguridad en el campus y tomar medidas preventivas para evitar incidentes no deseados.

- Eficiente gestión de recursos: Analizando grandes cantidades de datos, las universidades pueden optimizar la asignación de recursos, como salas de clases, laboratorios y personal docente, para maximizar su uso y reducir costos innecesarios.
- Mejorar la investigación: Permite a los investigadores universitarios analizar y correlacionar grandes conjuntos de datos, lo que puede conducir a avances significativos en diversas áreas, como la medicina, la ingeniería y las ciencias sociales.
- Aprendizaje personalizado: Las instituciones de educación superior podrán recolectar datos y analizarlos acerca de la forma de aprender de sus estudiantes, para poder ajustar los recursos y las actividades de aprendizaje ajustados al ritmo de cada uno de estos; permitiendo de esta forma un aprendizaje efectivo.
- Retención y el rendimiento estudiantil: Se pueden identificar patrones y factores que influyen en el éxito académico, para intervenir de manera temprana con estudiantes que puedan estar en riesgo de abandonar sus estudios o brindarles apoyo adicional para mejorar su rendimiento.
- Identificar tendencias educativas: Al analizar datos del sector educativo y del mercado laboral, las universidades pueden identificar tendencias emergentes en la educación y en el mundo profesional. Esto les permite adaptarse rápidamente a los cambios y mantenerse relevantes en un entorno educativo en constante evolución.
- Mejoras de programas académicos: Al analizar datos sobre la demanda de cursos, tasas de graduación y perspectivas laborales, las universidades pueden ajustar y optimizar sus programas académicos para que estén más alineados con las necesidades del mercado laboral y las preferencias de los estudiantes.
- Mejora en la experiencia del estudiante: Las universidades pueden analizar datos sobre el comportamiento de los estudiantes, su retroalimentación y sus preferencias. Con esta información, pueden mejorar la experiencia del estudiante, ofreciendo servicios más personalizados y adaptados a sus necesidades.

Para finalizar, la utilización de la ADM en las universidades ofrece grandes beneficios que conducen a una educación más eficiente, efectiva y centrada en el estudiante. Sin embargo, también es importante resolver las preocupaciones de privacidad y seguridad de los datos para garantizar que se utilicen con ética y responsabilidad.

## Bibliografía

- Aboelmaged, M., & Mouakket, S. (2020). Influencing models and determinants in big data analytics research: A bibliometric analysis. *Information Processing & Management*, 57(4), 102234. <https://doi.org/https://doi.org/10.1016/j.ipm.2020.102234>
- Albers, S. (2010). PLS and success factor studies in marketing. In V. Vinzi Esposito, W. W. Chin, J. Henseler, & H. (Eds) Wang (Eds.), *Springer*. Handbook of Partial Least Squares.
- Al-Maatouk, Q., Othman, M. S., Aldraiweesh, A., Alturki, U., Al-Rahmi, W. M., & Aljeraiwi, A. A. (2020). Task-Technology Fit and Technology Acceptance Model Application to Structure and Evaluate the Adoption of Social Media in Academia. *IEEE ACCESS*, 8, 78427–78440. <https://doi.org/10.1109/ACCESS.2020.2990420>
- Al-Rahmi, W. M., & Alkhalaf, S. (2021). AN EMPIRICAL INVESTIGATION OF ADOPTION BIG DATA IN HIGHER EDUCATION SUSTAINABILITY. *ENTREPRENEURSHIP AND SUSTAINABILITY ISSUES*, 9(2), 108–122. [https://doi.org/10.9770/jesi.2021.9.2\(7\)](https://doi.org/10.9770/jesi.2021.9.2(7))
- Al-Rahmi, W. M., Yahaya, N., Aldraiweesh, A. A., Alturki, U., Alamri, M. M., Bin Saud, M. S., Bin Kamin, Y., Aljeraiwi, A. A., & Alhamed, O. A. (2019). Big Data Adoption and Knowledge Management Sharing: An Empirical Investigation on Their Adoption and Sustainability as a Purpose of Education. *IEEE ACCESS*, 7, 47245–47258. <https://doi.org/10.1109/ACCESS.2019.2906668>
- Alyoussef, I. Y., & Al-Rahmi, W. M. (2022). Big data analytics adoption via lenses of Technology Acceptance Model: empirical study of higher education. *Entrepreneurship and Sustainability Issues*, 9(3), 399–413. [https://doi.org/10.9770/jesi.2022.9.3\(24\)](https://doi.org/10.9770/jesi.2022.9.3(24))
- Ley Orgánica de protección de datos personales, Registro Oficial 1 (2021).
- Baig, M. I., Shuib, L., & Yadegaridehkordi, E. (2019). Big data adoption: State of the art and research challenges. *Information Processing & Management*, 56(6), 102095. <https://doi.org/https://doi.org/10.1016/j.ipm.2019.102095>
- Barclay, D., Higgins, C., & Thompson, R. (1995). The partial least square (PLS) approach to casual modeling: Personal computer adoption and use as an illustration. In *Technology Studies (Special Issue of Research Methodology)* (Vol. 2, Issue 2, pp. 285–309).
- Botelho, B., & Bigelow, S. J. (2022). *Big data*. <https://www.techtarget.com/searchdatamanagement/definition/big-data?...>
- Carmine, E. G., & Zeller, R. A. (1979). Reliability and validity assessment. In J. L. Sullivan & R. G. Niemi (Eds.), *Quantitative Applications in the Social Sciences* (Vol. 17). McCune, Sara. <https://doi.org/10.1037/018269>

- Cepeda Carrión, G., & Roldan Salgueiro, J. L. (2004). Aplicando en la práctica la técnica PLS en administración de empresas. *Congreso de La ACEDE*, 1–30. <http://ciberconta.unizar.es/doctorado/PLSGabrielCepeda.pdf>
- Chamikara, M. A. P., Bertok, P., Liu, D., Camtepe, S., & Khalil, I. (2020). Efficient privacy preservation of big data for accurate data mining. *Information Sciences*, 527, 420–443. <https://doi.org/10.1016/j.ins.2019.05.053>
- Chatterjee, S., Rana, N. P., Dwivedi, Y. K., & Baabdullah, A. M. (2021). Understanding AI adoption in manufacturing and production firms using an integrated TAM-TOE model. *Technological Forecasting and Social Change*, 170, 120880. <https://doi.org/https://doi.org/10.1016/j.techfore.2021.120880>
- Chin, W. W. (1998). The Partial Least Squares Approach to Structural Modeling. In *Modern Methods for Business Research* (pp. 295–336).
- Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences* (Second). Lawrence Erlbaum.
- Danks, N. P., & Ray, S. (2018). Predictions from partial least squares models. In *Applying Partial Least Squares in Tourism and Hospitality Research* (pp. 35–52). Emerald Group Publishing Ltd. <https://doi.org/10.1108/978-1-78756-699-620181003>
- Davis, F. D. (1985). A technology acceptance model for empirically testing new end-user information systems: theory and results [Massachusetts Institute of Technology]. In *Massachusetts Institute of Technology*. <http://dspace.mit.edu/handle/1721.1/15192>
- Dijkstra, T. K., & Henseler, J. (2015). Consistent partial least squares path modeling. *MIS Quarterly*, 39(2), 297–316.
- Dishaw, M. T., & Strong, D. M. (1999). Extending the technology acceptance model with task-technology fit constructs. *Information and Management*, 36(1), 9–21.
- Elfeky, A. I. M., & Elbyaly, M. Y. H. (2021). The use of data analytics technique in learning management system to develop fashion design skills and technology acceptance. *Interactive Learning Environments*, 0(0), 1–18. <https://doi.org/10.1080/10494820.2021.1943688>
- Falk, R. F., & Miller, N. B. (1992). *A Primer for Soft Modeling.pdf*.
- Fornell, C., & Larcker, D. F. (1981). Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research*, 18(1), 39–50. <https://doi.org/10.2307/3151312>
- Garson, G. D. (2016). *Partial Least Squares: Regression & Structural Equation Models* (2016th ed.). Statistical Associates Publishing.
- Gefen, D., & Straub, D. (2005). A practical guide to factorial validity using PLS-Graph: Tutorial and annotated example. *Communications of the Association for Information Systems*, 16(5), 91–109. <https://doi.org/Article>

- Hair, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, M. (2014). Partial least squares structural equation modeling (PLS-SEM). *Sage Publisher*, 26(2), 106–121. <https://doi.org/10.1108/EBR-10-2013-0128>
- Hair, J. F., Ringle, C. M., & Sarstedt, M. (2011). PLS-SEM: Indeed a Silver Bullet. *The Journal of Marketing Theory and Practice*, 19(2), 139–152. <https://doi.org/10.2753/MTP1069-6679190202>
- Henseler, J., Hubona, G., & Ray, P. A. (2016). Using PLS Path Modeling in New Technology Research : Updated Guidelines. *Industrial Management & Data Systems*, 116(1), 2–20. <https://doi.org/10.1108/IMDS-09-2015-0382>
- Henseler, J., Ringle, C. M., & Sinkovics, R. R. (2009). The use of partial least squares path modeling in international marketing. *Advances in International Marketing*, 20(2009), 277–319. [https://doi.org/10.1016/0167-8116\(92\)90003-4](https://doi.org/10.1016/0167-8116(92)90003-4)
- Höök, K., & Löwgren, J. (2012). Strong concepts. *ACM Transactions on Computer-Human Interaction*, 19(3), 1–18. <https://doi.org/10.1145/2362364.2362371>
- Hu, L., & Bentler, P. M. (1998). Fit indices in covariance structure modeling: Sensitivity to underparameterized model misspecification. *Psychological Methods*, 3(4), 424–453.
- Islam, A. Y. M. A., Ahmad, K., Rafi, M., & Ming, Z. J. (2021). Performance-based evaluation of academic libraries in the big data era. *JOURNAL OF INFORMATION SCIENCE*, 47(4), 458–471. <https://doi.org/10.1177/0165551520918516>
- Ko, J., Paek, S., Park, S., & Park, J. (2021). A News Big Data Analysis of Issues in Higher Education in Korea amid the COVID-19 Pandemic. *SUSTAINABILITY*, 13(13). <https://doi.org/10.3390/su13137347>
- Maroufkhani, P., Wan Ismail, W. K., & Ghobakhloo, M. (2020). Big data analytics adoption model for small and medium enterprises. *Journal of Science and Technology Policy Management*, 11(2), 171–201. <https://doi.org/10.1108/JSTPM-02-2020-0018>
- Matthews, J., Love, P. E. D., Porter, S. R., & Fang, W. (2022). Smart data and business analytics: A theoretical framework for managing rework risks in mega-projects. *International Journal of Information Management*, 65(October 2021), 102495. <https://doi.org/10.1016/j.ijinfomgt.2022.102495>
- Ramirez-Anormaliza, R., Sabaté, F., Llinàs-Audet, X., & Lordan, O. (2017). Aceptación y uso de los sistemas e-learning por estudiantes de Grado de Ecuador: El caso de una universidad estatal. *Intangible Capital*, 13(3), 548–581. <https://doi.org/10.3926/ic.820>
- Rogers, E. M. (2003). *Diffusion of innovations*. Free Press.
- Sam, K. M., & Chatwin, C. R. (2018). UNDERSTANDING ADOPTION OF BIG DATA ANALYTICS IN CHINA: FROM ORGANIZATIONAL USERS PERSPECTIVE. *IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL ENGINEERING AND ENGINEERING MANAGEMENT*, 507–510.

- Schumacker, R. E., & Lomax, R. G. (2010). *A Beginner's Guide to Structural Equation Modeling: Third Edition* (Taylor & Francis Group, Ed.; 3rd ed.). Routledge. <http://books.google.com/books?id=58pWPxWPC90C&pgis=1>
- Shahbaz, M., Gao, C., Zhai, L., Shahzad, F., & Arshad, M. R. (2020). Moderating Effects of Gender and Resistance to Change on the Adoption of Big Data Analytics in Healthcare. *Complexity*, 2020. <https://doi.org/10.1155/2020/2173765>
- Shmueli, G., Sarstedt, M., Hair, J. F., Cheah, J. H., Ting, H., Vaithilingam, S., & Ringle, C. M. (2019). Predictive model assessment in PLS-SEM: guidelines for using PLSpredict. *European Journal of Marketing*, 53(11), 2322–2347. <https://doi.org/10.1108/EJM-02-2019-0189>
- Shorfuzzaman, M., Hossain, M. S., Nazir, A., Muhammad, G., & Alamri, A. (2019). Harnessing the power of big data analytics in the cloud to support learning analytics in mobile learning environment. *Computers in Human Behavior*, 92, 578–588. <https://doi.org/10.1016/j.chb.2018.07.002>
- Shu, J., Peng, L., Hu, Q., Tan, F., & Ge, X. (2019). Analysis of Behavioral Characteristics Based on Student's Personal Big Data. In A. Emrouznejad (Ed.), *PROCEEDINGS OF THE THIRD INTERNATIONAL CONFERENCE ON COMPUTER SCIENCE AND APPLICATION ENGINEERING (CSAE2019)*. ASSOC COMPUTING MACHINERY. <https://doi.org/10.1145/3331453.3362052>
- Sun, S., Cegielski, C. G., Jia, L., & Hall, D. J. (2018). Understanding the Factors Affecting the Organizational Adoption of Big Data. In *Journal of Computer Information Systems* (Vol. 58, Issue 3, pp. 193–203). Taylor and Francis Inc. <https://doi.org/10.1080/08874417.2016.1222891>
- TechTarget. (2022). *The Ultimate Guide to Big Data for Businesses* (C. Stedman, Ed.; Primera). TechTarget. <https://www.techtarget.com>
- Tole, A. A. (2013). Big Data Challenges. *Database Systems Journal*, IV(3).
- Tornatzky, L. G., & Fleisher, M. (1990). *The Processes of Technological Innovation*. Lexington Books.
- ur Rehman, M. H., Yaqoob, I., Salah, K., Imran, M., Jayaraman, P. P., & Perera, C. (2019). The role of big data analytics in industrial Internet of Things. *Future Generation Computer Systems*, 99, 247–259. <https://doi.org/10.1016/j.future.2019.04.020>
- Verma, S., Bhattacharyya, S. S., & Kumar, S. (2018). An extension of the technology acceptance model in the big data analytics system implementation environment. *Information Processing and Management*, 54(5), 791–806. <https://doi.org/10.1016/j.ipm.2018.01.004>

- Watson, H. J. (2019). Update tutorial: Big data analytics: Concepts, technology, and applications. *Communications of the Association for Information Systems*, 44(1). <https://doi.org/10.17705/1CAIS.04421>
- Wold, H. (1974). Causal flows with latent variables. *European Economic Review*, 5(1), 67–86. [https://doi.org/10.1016/0014-2921\(74\)90008-7](https://doi.org/10.1016/0014-2921(74)90008-7)
- Xu, Z., Ge, Z., Wang, X., & Skare, M. (2021). Bibliometric analysis of technology adoption literature published from 1997 to 2020. *Technological Forecasting and Social Change*, 170, 120896. <https://doi.org/10.1016/j.techfore.2021.120896>
- Zhou, X., & Wu, X. (2022). Teaching Mode Based on Educational Big Data Mining and Digital Twins. *COMPUTATIONAL INTELLIGENCE AND NEUROSCIENCE*, 2022. <https://doi.org/10.1155/2022/9071944>

**UNEMI**  
UNIVERSIDAD ESTATAL DE MILAGRO

*¡Evolución académica!*

@UNEMIEcuador

