



UNIVERSIDAD  
**NACIONAL**  
DE COLOMBIA

# **FACTORES QUE INFLUYEN EN LA ADOPCIÓN DE MACHINE LEARNING EN EMPRESAS COLOMBIANAS**

**Sergio Enrique Pulido Morales**

Universidad Nacional de Colombia

Facultad de Ciencias Económicas

Bogotá D.C, Colombia

2020

# **FACTORES QUE INFLUYEN EN LA ADOPCIÓN DE MACHINE LEARNING EN EMPRESAS COLOMBIANAS**

**Sergio Enrique Pulido Morales**

Tesis presentada como requisito parcial para optar por el título de  
**Magister en Administración**

Directora:

Ph.D. Elizabeth Eliana Grandón Toledo

Codirectora:

Ph.D. Beatriz Helena Díaz Pinzón

Línea de Investigación:

Sistemas de Información Gerencial

Grupo de investigación:

Grupo de Investigación en Sistemas y Tecnologías de la Información y de la  
Comunicación en las Organizaciones (GISTIC)

Universidad Nacional de Colombia

Facultad de Ciencias Económicas

Bogotá D.C, Colombia

2020

*Quand le mystère est trop  
impressionnant, on n'ose pas  
désobéir*

Antoine de Saint-Exupéry

## **Agradecimientos**

En primer lugar agradezco a la Universidad Nacional de Colombia y a la Universidad Pública de Navarra, por abrirme las puertas para continuar mi formación tanto académica, profesional como personal. A mis directoras y profesoras Elizabeth Grandón y Beatriz Díaz por todo el apoyo y asesorías brindadas, tanto en la investigación como durante mis estudios, este proceso no hubiera sido tan fructífero sin su gran contribución. A mis compañeros del grupo de investigación GISTIC por el continuo y enriquecedor compartir de saberes. A mi mamá y mi papá, quienes fundaron en mí unas bases sólidas para ser la persona que soy hoy en día y poder así culminar mis proyectos. A mis hermanos, mis abuelitos, mi tío Cesar Pulido, mi prima Wendy Fernández y mi amigo Felipe Samacá, quienes de una u otra forma han estado presentes en la continua escalada de peldaños en mi vida.

## Resumen

*Machine learning* ha sido catalogada como una tecnología que puede aportar en la optimización de la operación organizacional y generar nuevas líneas de negocio. Sin embargo, no ha tenido la adopción que instituciones como la CEPAL esperan y la literatura no expresa si los modelos de adopción de tecnologías actuales explican la intención de uso de esta tecnología en específico, y en especial, si es necesario realizar alguna adecuación para ser aplicado a un entorno colombiano. Es por ello que utilizando un enfoque multimetodológico, a partir de una revisión sistemática de la literatura se identificaron factores que podrían afectar la adopción de *machine learning*, los cuales fueron contrastados con los indicados por expertos de Chile, Colombia y España a través del método Delphi. Como resultado se obtuvieron ocho factores los cuales fueron propuestos en un modelo de investigación, el cual fue validado a través de una encuesta aplicada a empresas colombianas. Mediante estadística multivariante con modelamiento de ecuaciones estructurales, se encontró que las condiciones facilitadoras, facilidad de uso, utilidad, apoyo a los directivos y gestión de datos son influyentes en la adopción de *machine learning* en un entorno empresarial colombiano. Por su parte, la confiabilidad e integridad, influencia social y el precio-valor parecieran no incidir en el fenómeno de adopción.

**Palabras clave:** *Machine Learning*, modelo de adopción, método Delphi, PLS-SEM

## Abstract

Machine learning has been classified as a technology that can contribute to the optimization of the organizational operation and generate new business lines. However, it has not had the adoption that institutions such as CEPAL expect and the literature does not state whether the models for the adoption of current technologies explain the intention to use this specific technology, and especially, whether it is necessary to make any adjustments to be applied to a Colombian environment. Using a multi-methodological approach, from a systematic literature review, factors that could affect the adoption of machine learning were identified, which were contrasted with those indicated by experts from Chile, Colombia, and Spain through a Delphi method. As a result, eight factors were obtained, which were proposed in a research model that was validated through a survey applied to Colombian companies. Using multivariate statistics with structural equation modeling, it was found that facilitating conditions, ease of use, usefulness, executive support and data management are influential in adopting machine learning in a Colombian business environment. On the other hand, reliability and integrity, social influence, and price-value do not seem to influence the adoption phenomenon.

**Keywords:** *Machine Learning*, Adoption Model, Delphi method, PLS-SEM

# Contenido

	Pág.
Resumen .....	V
Lista de figuras.....	IX
Lista de tablas .....	X
<b>1. Introducción .....</b>	<b>12</b>
1.1. Contexto.....	13
1.2. Planteamiento del problema .....	15
1.3. Objetivos .....	15
1.3.1 Objetivo general.....	15
1.3.2 Objetivos específicos .....	15
<b>2. Metodología de la Investigación.....</b>	<b>17</b>
2.1. Revisión Sistemática de Literatura .....	19
2.2. Método Delphi .....	22
2.2.1 Definición.....	23
2.2.2 Conformación del grupo de expertos .....	23
2.2.3 Ejecución de Rondas de Consulta .....	26
2.2.4 Resultados.....	28
2.3. Validación Modelo .....	28
2.3.1 Modelo.....	28
2.3.2 Instrumento.....	29
2.3.3 PLS-SEM.....	32
<b>3. Marco Conceptual .....</b>	<b>37</b>
3.1. Adopción de Tecnologías .....	37
3.2. Modelos de Adopción de Tecnologías.....	38
3.3. <i>Machine Learning</i> .....	41
3.4. Factores de Adopción de <i>Machine Learning</i> a partir de la Literatura .....	42
<b>4. Factores de Adopción a partir de Expertos (Aplicación Método Delphi) .....</b>	<b>46</b>
<b>5. Modelo de Adopción de <i>Machine Learning</i>.....</b>	<b>52</b>
5.1. Construcción del Modelo de Adopción de <i>Machine Learning</i> .....	52
5.2. Validación Modelo de Medida.....	56
5.3. Validación Modelo Estructural .....	58
5.4. Intención de Uso y Uso Actual de las Empresas Colombianas Encuestadas ...	61

<b>6. Conclusiones y Recomendaciones .....</b>	<b>63</b>
6.1. Resultados de la Investigación.....	63
6.1.1 Hallazgos a partir de la RSL más lo inferido de los expertos por medio del método Delphi.....	63
6.1.2 Hallazgos a partir de la validación del modelo de adopción planteado .....	64
6.2. Discusión de Resultados.....	65
<b>A. Anexo: Matriz para selección de expertos por medio del biograma del experto.....</b>	<b>69</b>
<b>B. Anexo: Resultados biograma del experto.....</b>	<b>71</b>
<b>C. Anexo: Cuestionario para determinar coeficiente experto. ....</b>	<b>75</b>
<b>D. Anexo: Cuestionario para validación modelo.....</b>	<b>76</b>
<b>E. Anexo: Factores que pueden influir en la adopción de <i>machine learning</i> según la literatura. ....</b>	<b>79</b>
<b>F. Anexo: Cargas cruzadas de los indicadores y las variables latentes.....</b>	<b>83</b>



## Lista de figuras

	Pág.
<b>Figura 2-1.</b> Multimetodología aplicada en la investigación. Elaboración propia.....	18
<b>Figura 2-2.</b> Metodología de la Revisión sistemática de la literatura (Leitner & Rinderle-Ma, 2014).....	20
<b>Figura 2-3.</b> Resumen selección de documentos. Elaboración propia.....	22
<b>Figura 2-4.</b> Metodología método Delphi (Reguant & Torrado, 2016).....	23
<b>Figura 2-5.</b> Resumen Clasificación Posibles Expertos. Elaboración propia.....	24
<b>Figura 3-1.</b> Modelo de aceptación tecnológica (TAM) (Davis, 1989).....	38
<b>Figura 3-2.</b> Teoría Unificada de aceptación y uso de la tecnología (Venkatesh et al., 2003).....	39
<b>Figura 4-1.</b> Resumen proceso Método Delphi. Elaboración propia. ....	46
<b>Figura 5-1.</b> Modelo de adopción de <i>machine learning</i> . Elaboración propia. ....	53
<b>Figura 5-2.</b> Modelo Estructural. Resultante de SmartPLS-3.....	60
<b>Figura 5-3.</b> Uso actual de ML por sector económico. Elaboración propia.....	62
<b>Figura 5-4.</b> Intención de usar ML por empresas que actualmente no expresan estar de acuerdo con la generación actual de proyectos con ML. Elaboración propia. ....	62

## Lista de tablas

	Pág.
<b>Tabla 1-1.</b> Evolución de la Digitalización (Katz, 2017). .....	13
<b>Tabla 2-1.</b> Cantidad de documentos obtenidos en cada base de datos, por cada ecuación de búsqueda. ....	21
<b>Tabla 2-3.</b> Ponderación de los factores de fundamentación en función del grado de influencia.....	26
<b>Tabla 2-4.</b> Evaluación del coeficiente de competencia experta de los candidatos. ....	26
<b>Tabla 2-5.</b> Información demográfica general Colombia.....	31
<b>Tabla 2-6.</b> Sub-clasificación de empresas de servicios en Colombia. ....	31
<b>Tabla 2-7.</b> Cargo persona encuestada por empresa. ....	31
<b>Tabla 2-8.</b> Número de muestra sugerido (Marcoulides y Saunders, 2006, citado en Martínez & Fierro, 2018). ....	32
<b>Tabla 3-1.</b> Agrupación de factores de adopción de <i>machine learning</i> encontrados en la literatura.....	43
<b>Tabla 4-1.</b> Asociación de factores de adopción de <i>machine learning</i> mencionados por los expertos. ....	47
<b>Tabla 4-2.</b> Grado de consenso de los factores de adopción de <i>machine learning</i> mencionados por los expertos en la primera iteración.....	48
<b>Tabla 4-3.</b> Grado de consenso de los factores de adopción de <i>machine learning</i> que no lograron una convergencia en la segunda iteración. ....	48
<b>Tabla 4-4.</b> Resultados cuantificación promedio del grado de influencia de los factores de adopción mencionados por los expertos, en la adopción de <i>machine learning</i> .....	49
<b>Tabla 4-5.</b> Comparación factores de adopción de <i>machine learning</i> encontrados en la RSL y los mencionados por los expertos. ....	50
<b>Tabla 4-6.</b> Resultados cuantificación promedio del grado de influencia de los factores resultantes de la asociación de los mencionados por los expertos y los agrupados en la RSL, en la adopción de <i>machine learning</i> . ....	50
<b>Tabla 4-7.</b> Categorización de factores de adopción de <i>machine learning</i> resultantes de la asociación del método Delphi y la RSL. ....	51
<b>Tabla 5-1.</b> Validez convergente. ....	56
<b>Tabla 5-2.</b> Cargas de las variables de cada constructo.....	56
<b>Tabla 5-3.</b> Cargas de las variables de los constructos ajustados. ....	57
<b>Tabla 5-4.</b> Validez convergente con los constructos ajustados. ....	58

<b>Tabla 5-5.</b> Criterio Fornell-Larcker de las variables latentes.....	58
<b>Tabla 5-6.</b> Resultados Bootstrapping. ....	59
<b>Tabla 5-7.</b> Tamaño del efecto ( $f^2$ ).....	61
<b>Tabla A-1.</b> Matriz para selección de expertos por medio del biograma del experto. ....	69
<b>Tabla B-1.</b> Resultados biograma de los expertos académicos orientados a gerencia de TI.....	71
<b>Tabla B-2.</b> Resultados biograma de los expertos académicos orientados a inteligencia artificial. ....	72
<b>Tabla B-3.</b> Resultados biograma de los expertos profesionales gerentes, líderes, analistas y/o desarrolladores de TI. ....	74
<b>Tabla E-1.</b> Factores encontrados en la literatura que pueden influir en la adopción de <i>machine learning</i> . ....	79
<b>Tabla F-1.</b> Cargas cruzadas de los indicadores y las variables latentes Colombia.....	83

# 1. Introducción

El constante avance tecnológico ha generado herramientas y tecnologías, las cuales al ser adoptadas por una organización, han permitido mejorar su estructura, sus procesos, sus habilidades individuales y su productividad, logrando así un fortalecimiento de sus capacidades organizacionales, de su estrategia y de sus productos o servicios, y así finalmente llegar a diferenciarse de la competencia, posicionarse estratégicamente y obtener beneficios financieros (Díaz, Gómez, García, Melo, & Sanabria, 2017). Sin embargo, la adopción de una nueva tecnología en muchos casos se ha vuelto un tema crítico y de difícil solución (Grandon, Aravena, Araya, Ramirez-Correa, & Alfaro-Perez, 2018), generando el desafío para los investigadores de estudiar los problemas que se presentan a la hora de adoptar estas nuevas tecnologías (Grandon et al., 2018).

Mediante la presente investigación multimetodológica, se aporta a dicho desafío respondiendo qué factores deben ser considerados por los tomadores de decisiones en las empresas colombianas para adoptar una tecnología que ha sido catalogada como una herramienta fundamental para el éxito continuo del negocio (Studio SAP, 2018): *machine learning*.

En primer lugar, en el presente capítulo se expone el contexto de la situación problema, en un segundo capítulo se realiza una descripción de la metodología que se ha usado y se ahonda en los métodos de investigación. Luego, en un tercer capítulo se expone un marco conceptual en el cual esta soportado el estudio. Posteriormente, en un cuarto capítulo, se presenta la inferencia de factores de adopción para *machine learning* a través de expertos usando método Delphi. En un quinto capítulo se expone el modelo propuesto y su respectiva validación en el entorno empresarial colombiano, para finalmente discutir de los resultados obtenidos y proponer recomendaciones para futuras investigaciones.

## 1.1. Contexto

Según Katz & Callorda (2017) la digitalización evoluciona por olas y mediante tres fases: desarrollo, adopción y periodo de impacto económico y social. En la Tabla 1-1 se observa que la tercera ola es la última que ha entrado en el periodo de impacto económico y social, no obstante, aún se encuentra en adopción. Esta ola incluye la difusión de tecnologías enfocadas en el mejoramiento de la toma de decisiones gerenciales y la automatización de operaciones rutinarias en la producción de bienes y servicios. Esta ola está asociada a la generación de nuevas capacidades y maneras de hacer negocios (Mooney & Kraemer, 1996, citado en Díaz, Gómez, García, Melo, & Sanabria, 2017), logrando un fortalecimiento de las capacidades organizacionales, de la estrategia y de los productos o servicios (Díaz et al., 2017).

**Tabla 1-1.** Evolución de la Digitalización (Katz, 2017).

Innovación tecnológica	Desarrollo	Adopción	Periodo de impacto económico y social
Primera Ola: sistemas informáticos de gestión, procesamiento automatizado de datos y telecomunicaciones móviles.	1950 - 1975	1960 – 2000	1990 – 2010
Segunda Ola: masificación de internet, plataformas digitales, computación en la nube.	1970 - 1990	1995 – en curso	2005 – en curso
Tercera Ola: Internet de las cosas, robótica, inteligencia artificial, aprendizaje de máquina, cadena de bloques (blockchain)	1980 - en curso	2010 - en curso	A partir de 2020

La inteligencia artificial (IA), ubicada dentro de la tercera ola de la transformación digital, es definida por uno de los padres en esta materia, Marvin Minsky, como la ciencia de construir máquinas para que hagan cosas que, si las hicieran los humanos, requerirían inteligencia (Alfonso, Cazorla, Colomina, Escolano, & Lozano, 2003). D'Addario (2019) la define como una ciencia con un amplio campo de estudio dedicado al análisis del cerebro humano y la inteligencia, con el fin de modelar matemáticamente diferentes lógicas y procesos que ayuden a facilitar y automatizar problemas en diferentes áreas del conocimiento. Dentro de los procesos de IA se han clasificado los robots, *chatbots*, sistemas de recuperación y extracción de información, máquinas de aprendizaje

(*machine learning*) y aprendizaje profundo (*deep learning*) (Ministerio de Educación Español, 2017).

Bishop (2016) define el *machine learning* (ML) como un conjunto de algoritmos para mapear datos, aprender de ellos y luego ser capaz de hacer una predicción o sugerencia sobre algo. Se asemeja al comportamiento humano, cuando una persona se enfrenta con un problema difícil, el cual no entiende, primero comienza a recordarlo. Aunque el método requiere cierta cantidad de cálculos, una vez que el modelo termina el entrenamiento puede usarse para obtener un resultado preciso de largo plazo y de forma instantánea (Fang & George, 2017).

Compañías de todo el mundo están aprovechando las nuevas capacidades que técnicas como *machine learning* pueden aportar en la optimización de su operación actual o en la generación de nuevos modelos de negocio (Endeavor & Everis, 2018). Está presente en la vida diaria actual, por ejemplo: Amazon utiliza el ML para predecir qué productos se querrán comprar, Gmail lo usa para filtrar mensajes de spam de la bandeja de entrada, las recomendaciones de Netflix se basan en algoritmos de aprendizaje automático, entre otros (Norman & Bolivar, 2019).

De acuerdo con la encuesta global 2017 de PwC, las empresas e industrias tienen grandes expectativas sobre la transformación que tendrán sus negocios adoptando esta tecnología y por esta razón, están haciendo fuertes inversiones para capitalizar la oportunidad y no quedarse atrás (ProMéxico, 2017). No en vano, el ML, ocupa el número uno en el ranking 2017 de las tendencias estratégicas en tecnología (Marr, 2017).

Un estudio realizado por Forrester Consulting en 2018, presenta que el 98% de los tomadores de decisiones globales, que contestaron su encuesta, creen que tecnologías analíticas predictivas y *machine learning* son fundamentales para el éxito continuo de su negocio (Studio SAP, 2018). De igual forma, Ovanessoff & Plastino (2017) expresan que el ML ofrece una oportunidad excepcional para que las economías sudamericanas aborden su déficit de productividad y aumenten su dinamismo de manera más sostenible.

## 1.2. Planteamiento del problema

A pesar que el *machine learning* se encuentra en una etapa de adopción desde el 2010 (CEPAL, 2018), según la última gran encuesta del MinTIC en 2017, Colombia presenta un índice de adopción por debajo del dos por ciento (R. L. Katz, 2017). Aunque todos quieren usarla, pocos son los que se han puesto a la tarea de desarrollar esta tecnología y presentar soluciones eficientes (Revista Dinero, 2019). Fermín Bueno, durante el noveno congreso de Asobolsa y la BVC, opina que el país, se encuentra atrasado frente a los desarrollos en tecnología que se han hecho en Europa, Asia y Estados Unidos, particularmente en el área de Inteligencia Artificial (Jiménez, 2017).

Los empresarios indican que el mayor reto que enfrenta el *machine learning*, englobado en la inteligencia artificial, para escalar en América Latina es la adopción de esta tecnología (Endeavor & Everis, 2018). La literatura ha abordado ampliamente el desafío de explicar el fenómeno de adopción a través de distintos modelos (Grandón, Nasco, & Mykytyn, 2011). Dentro de los más utilizados se encuentran, el modelo de aceptación tecnológica de Davis (Davis, 1989) y la teoría unificada de aceptación y uso de la tecnología de Venkatesh (Venkatesh, Morris, Davis, & Davis, 2003). Sin embargo, al realizar una revisión de literatura, se encuentran pocos artículos que utilizan algún modelo en específico para estudiar los factores que influyen en la adopción de *machine learning*, y más específicamente no se relaciona la adopción en Colombia, por lo que nace la pregunta: ¿Cuáles factores influyen en la adopción de *machine learning* en empresas colombianas?

## 1.3. Objetivos

### 1.3.1 Objetivo general

Determinar factores que influyen en la adopción de *machine learning* en empresas colombianas.

### 1.3.2 Objetivos específicos

- Identificar a través de la revisión de literatura modelos que permitan evaluar factores que influyen la adopción de *machine learning*.
- Inferir factores que influyen en la adopción de *machine learning* a partir de expertos.

- Construir un modelo de investigación, a partir de la revisión de la literatura y de lo inferido de los expertos, que permita evaluar factores que influyen en la adopción de *machine learning* en empresas colombianas.
- Validar el modelo de investigación a partir de un instrumento aplicado a empresas colombianas.



## 2. Metodología de la Investigación

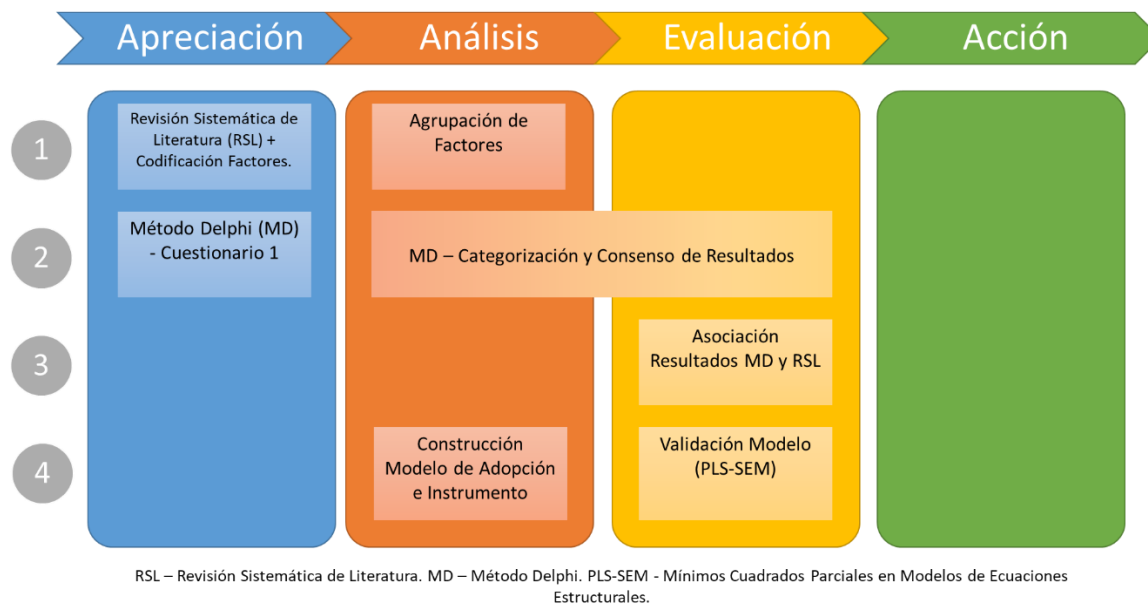
Una metodología se encamina al análisis y comprensión de un sistema, se pueden usar varias metodologías separadas para observar la misma situación y obtener diferentes resultados, es allí donde la multimetodología permite aprovechar estas diferentes visiones y unir las en una sola (Mingers & Gill, 1997), combinar metodologías que cubran de forma más amplia el problema de estudio y usar los componentes fundamentales de cada una para abordar dicha situación de una forma más integral (Sepúlveda-López, 2014).

Esta idea está soportada en el paradigma de realismo crítico de Bhaskar, el cual acepta que el acceso al mundo es limitado en tanto está condicionado por las percepciones y teorías con las que sea analizado (Mingers, Mutch, & Willcocks, 2013); por lo que se infiere que el mundo se divide en diferentes dominios mediante los cuales se puede abordar un suceso, es por ello su intención de fusionar dos puntos de vista del mundo para que estos se complementen y de este modo brindar una visión completa del objetivo de estudio (Parada, 2004; Parra, 2016).

Teniendo en cuenta lo anterior, se propone para efectos de esta investigación utilizar la multimetodología de Mingers & Brocklesby (1997) para dar respuesta a la pregunta de estudio, la cual se ve resumida en la Figura 2-1. Se distinguen cuatro fases:

- **Apreciación:** Se hace énfasis en la valoración de lo que se percibe como estado actual. Las apreciaciones ciertas están construidas sobre definiciones, conceptos, teorías, entre otros, previos y reconocidos (Holguín-Ontiveros, 2015).
- **Análisis:** En esta etapa es fundamental razonar respecto a la información de la etapa de apreciación para dilucidar los ¿por qué? de las percepciones. Se destaca en el proceso la utilización de métodos de análisis para contrastar los resultados de la apreciación (Holguín-Ontiveros, 2015).

- **Evaluación:** Se evalúan los postulados y proposiciones afirmados dentro de la investigación teniendo en cuenta el objetivo de visualizar, diferenciadamente, la situación problema (Holguín-Ontiveros, 2015).
- **Acción:** Para objeto de este estudio, es la presentación y socialización de los resultados obtenidos durante la investigación.



**Figura 2-1.** Multimetodología aplicada en la investigación. Elaboración propia.

Teniendo en cuenta esta metodología, se realiza en primera instancia una revisión sistemática de la literatura (RSL) para identificar modelos que pueden evaluar e identificar factores que influyen en la adopción de *machine learning*. Una revisión sistemática es una manera de evaluar e interpretar toda la investigación disponible, que sea relevante respecto a una interrogante de investigación en particular, en un área temática o fenómeno de interés (Kitchenham, 2004). Se enlista todos los factores que se encuentran en la literatura y posteriormente, se categoriza los factores en los modelos encontrados y otros factores en términos similares.

Por medio del método Delphi (MD) se infieren factores que influyen en la adopción de *machine learning* considerados por los expertos. El método consiste en la selección de un grupo de expertos a los que se les pregunta su opinión sobre alguna temática en común. Las estimaciones de los expertos se realizan en sucesivas rondas, anónimas, a objeto de tratar de conseguir consenso, pero con la máxima autonomía por parte de los participantes (Astigarraga, 2008). Previamente se construye el instrumento a aplicar con la respectiva validación.

Realizando la categorización de los resultados encontrados en la revisión con expertos, se contrasta con lo identificado mediante la revisión sistemática de literatura, de esta forma se genera una asociación de factores, los cuales serán la base de los constructos hipotéticos de un modelo de adopción de *machine learning* en empresas colombianas

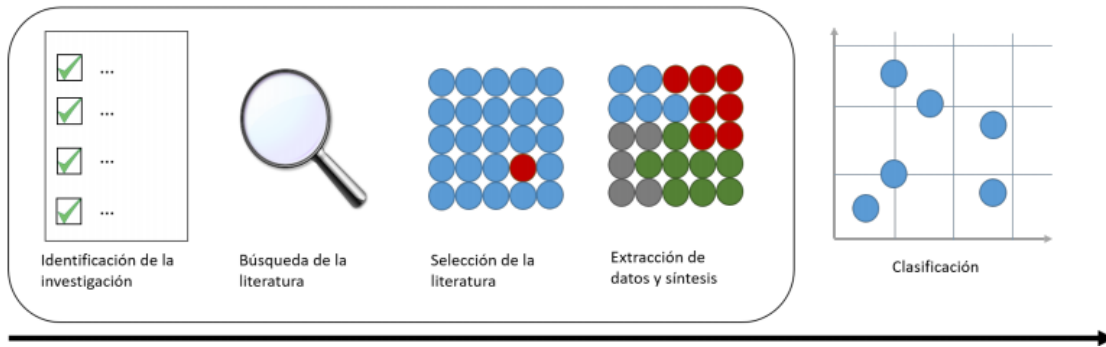
Este modelo es validado por medio de mínimos cuadrados parciales en modelos de ecuaciones estructurales (PLS-SEM). Uno de los objetivos fundamentales de esta técnica, de estadística multivariante, es incrementar la capacidad explicativa de la comprobación empírica de la teoría (Martínez & Fierro, 2018). La data para esta validación se obtiene por medio de un instrumento, aplicado a tomadores de decisiones de empresas colombianas, el cuál es construido y revisado por parte de expertos.

## 2.1. Revisión Sistemática de Literatura

La revisión sistemática de literatura (RSL), tiene como objetivo una búsqueda sistemática, evaluación, análisis y síntesis de pruebas de investigación para alcanzar conclusiones generales (Ridley, 2008); generando un reporte transparente el cuál puede ser replicado sin ningún sobresalto. Además, el enorme aumento en el número de publicaciones disponibles, considerando que Internet se ha convertido en el medio predominante de intercambio de información, hace que sea imposible para un individuo leer todo lo que se publica. Por lo tanto, las revisiones sistemáticas pueden proporcionar una síntesis de evidencia sobre un tema específico que puede ser un gran ahorro de tiempo y de recursos para profesionales e investigadores (Riaño, 2018).

El trabajo de Leitner & Rinderle-Ma (2014) es usado como base para la metodología, descrita en la Figura 2-2, usada en la RSL de esta investigación. En primer lugar, a partir del objetivo de la investigación se estructura la ecuación de búsqueda la cual se usa en motores de búsqueda y/o bases de datos. Posterior a ello, se realiza una selección de la literatura encontrada y se extrae la información relevante mediante categorizaciones y/o codificaciones.

## Revisión sistemática de la literatura



**Figura 2-2.** Metodología de la Revisión sistemática de la literatura (Leitner & Rinderle-Ma, 2014).

El objetivo de la RSL en la presente investigación es identificar factores que influyen en la adopción de *machine learning* y modelos que evalúan la adopción de esta tecnología, por lo que se construye la siguiente ecuación de búsqueda, incluyendo términos además de inglés, en francés, español y portugués en las bases de datos que contienen textos en estos idiomas:

**ECU1:** ("machine learning" OR "aprendizado de máquina" OR "apprentissage automatique" OR "máquina de aprendizaje") AND ("adoption" OR "adopción" OR "adoção") AND ("factors" OR "factores" OR "fatores" OR "facteurs")

Con la finalidad de abarcar mayor literatura se decide incluir el término que enmarca el *machine learning* que es la inteligencia artificial, de esta forma poder abstraer factores de adopción generales para esta rama tecnológica y modelos que estudian la adopción del marco global, para luego poder validar por medio de los expertos si estos se aplican también para *machine learning* en específico. La ecuación resultante es:

**ECU2:** ("machine learning" OR "aprendizado de máquina" OR "apprentissage automatique" OR "máquina de aprendizaje" OR "artificial intelligence" OR "inteligencia artificial" OR "inteligência artificial" OR "intelligence artificielle") AND ("adoption" OR "adopción" OR "adoção") AND ("factors" OR "factores" OR "fatores" OR "facteurs")

Por último, se decide incluir el término de "factores críticos de éxito" (FCE), ya que varios modelos trabajan estos y asocian algunos como factores de adopción de tecnologías. Asimismo, se incluye el término "Intención de uso", puesto que como menciona

Salahshour, Nilashi, & Mohamed (2018) se utiliza para evaluar la intención de adopción de una innovación en el futuro. Con esto la ecuación finalmente es:

**ECU3:** ("machine learning" OR "aprendizado de máquina" OR "apprentissage automatique" OR "máquina de aprendizaje" OR "artificial intelligence" OR "inteligencia artificial" OR "inteligência artificial" OR "intelligence artificielle") AND ("adoption" OR "adopción" OR "adoção" OR "Intention to use" OR "intención de uso" OR "intenção de usar" OR "intention d'utiliser") AND ("factors" OR "factores" OR "fatores" OR "facteurs" OR "CSF" OR "KSF" OR "FCE")

Con el fin de encontrar documentación potencialmente relevante que permita cumplir el objetivo descrito, las anteriores ecuaciones de búsqueda son usadas en las bases de datos Scopus (<https://www.scopus.com>), Web of Science (<https://webofknowledge.com>), ScienceDirect (<https://www.sciencedirect.com>), Scielo (<https://www.scielo.org/>) y los repositorios universitarios de la Universidad Nacional de Colombia (<https://bibliotecas.unal.edu.co>) y de la Universidad Pública de Navarra (<https://www.unavarra.es/biblioteca>). En la Tabla 2-1 se puede observar la cantidad de documentos resultantes en cada base de datos y por cada ecuación. Cada búsqueda se realizó por título, resumen y palabras claves.

**Tabla 2-1.** Cantidad de documentos obtenidos en cada base de datos, por cada ecuación de búsqueda.

	Ecuación solo ML	Ecuación incluyendo IA	Ecuación incluyendo FCE
<b>Scielo</b>	0	0	0
<b>ScienceDirect</b>	13	17	26
<b>WoS</b>	25	38	41
<b>BD UPNA</b>	0	669	692
<b>Scopus</b>	86	278	294
<b>BD UNAL</b>	307	767	796
<b>Total</b>	<b>431</b>	<b>1769</b>	<b>1849</b>

Continuando con la metodología se procede a seleccionar la literatura de la siguiente manera:

- Filtro por área de conocimiento o temática: dependiendo de la base de datos utilizada se aplicaron criterios de búsqueda para incluir solamente las áreas de conocimiento: ciencias de la computación, ciencias sociales, ciencias de la

decisión, negocios, administración y/o contabilidad; o las temáticas: inteligencia artificial, adopción, *machine learning*, modelos, aceptación, factores humanos, gestión, éxito, satisfacción y organizaciones.

- Filtro por idioma: se excluyeron los documentos que se encontraron con idiomas diferentes al español, francés, inglés o portugués.
- Eliminación de duplicados: cada vez que se realizaba una búsqueda en una base de datos se eliminaban los documentos que eran resultantes y se encontraban en anteriores búsquedas.
- Selección de documentos por pertinencia y con acceso: se discriminaron los documentos que, al hacer lectura de su título, palabras claves y resumen no se consideraron potencialmente relevantes. Adicional, se validó que no se tuviera restricción de acceso al documento completo.
- Exclusión de documentos no relevantes después de lectura total de los mismos.

Este procedimiento se realizó para todas las ecuaciones de búsqueda de forma cíclica concluyendo el proceso con un total de quince documentos relevantes para ser analizados. En la Figura 2-3 se visualiza el resumen de la selección de documentos desagregando cada tarea realizada en cada iteración.

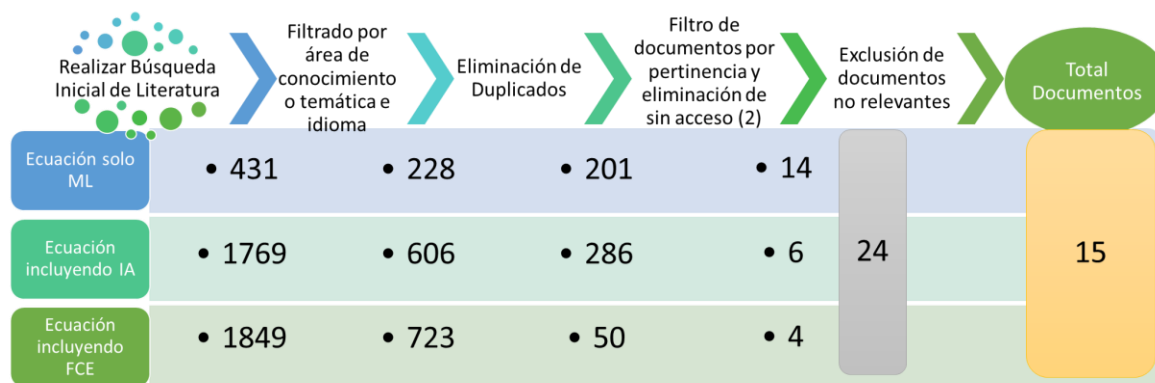


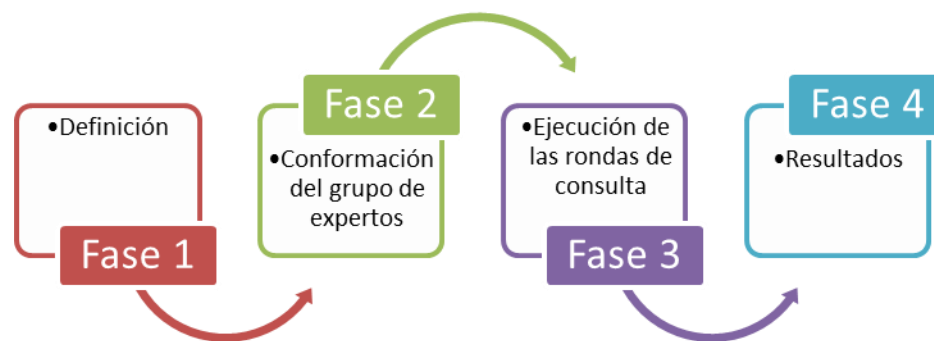
Figura 2-3. Resumen selección de documentos. Elaboración propia.

## 2.2. Método Delphi

El método Delphi se basa en el principio de la inteligencia colectiva y consiste en la aplicación sucesiva de cuestionarios a un grupo de expertos en varias rondas (Riaño & Palomino, 2015), lo que se persigue con esta técnica es obtener el grado de consenso o acuerdo de los especialistas sobre el problema planteado, utilizando los resultados de

investigaciones anteriores, en lugar de dejar la decisión a un solo profesional (Varela, Díaz, & García, 2012). Sus ventajas radican en la aplicación flexible y dinámica y la retroalimentación entre expertos participantes; es usado para estructurar el proceso de comunicación grupal para que ésta sea efectiva al permitir a un grupo de individuos tratar problemas complejos (de Liaño & Pascual-Ezama, 2012).

Por medio de la participación de expertos utilizando método Delphi, se identifican factores que pueden influir en la adopción de *machine learning*, implementando un método de cuatro fases: definición, conformación del grupo de expertos, ejecución de las rondas de consulta y resultados (Reguant & Torrado, 2016), el cual se puede observar en la Figura 2-4.



**Figura 2-4.** Metodología método Delphi (Reguant & Torrado, 2016)

### 2.2.1 Definición

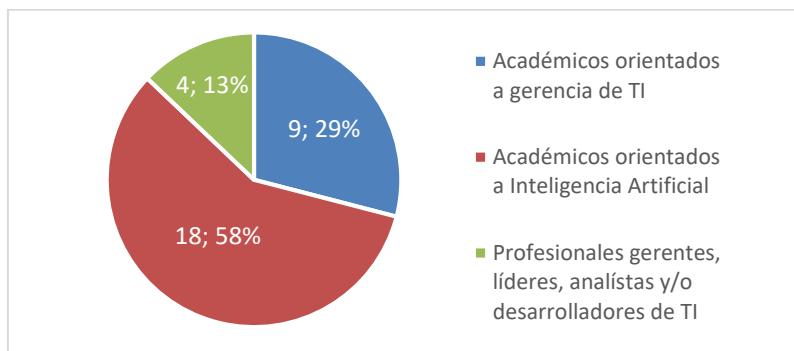
Reguant y Torrado (2016) lo definen como la fase en donde se formula el objetivo de la consulta y se identifican las dimensiones a tratarse y la literatura base. Para efectos de esta investigación el objetivo es identificar y logra un consenso de cuáles son los factores que influyen en la adopción de *machine learning*. En cuanto a la literatura base, se toma la revisión sistemática de literatura previa.

### 2.2.2 Conformación del grupo de expertos

Siendo el grupo de expertos la fuente de información, se entiende la importancia que tiene su correcta selección y participación. Este es uno de los elementos que condicionan su éxito (Reguant & Torrado, 2016). La literatura propone un tamaño de panel comprendido entre siete y treinta expertos provenientes de diferentes grupos de interés implicados en el estudio (Cabrero & Llorente, 2013; Malla & Zabala, 1978; García & Lena, 2018; Landeta,

2002). Además, en la selección del número de expertos se debe prever el número de rechazos y abandonos en el proceso por parte de los mismos, anticipando esta eventualidad en la realización del criterio de selección previo (García & Lena, 2018).

Para este estudio se contactaron 32 posibles expertos de diferentes países (Canadá, Chile, Colombia, España y Perú), tanto a nivel profesional como académicos. Se suele hacer división de los perfiles de los expertos ubicándolos en el ámbito profesional y académico, para de esta forma poder tener un equipo integro (García & Lena, 2018). Por esto, en esta investigación se realiza división de los expertos en tres categorías: académicos orientados a gerencia de TI (9), académicos orientados a Inteligencia Artificial (18) y profesionales gerentes, líderes, analistas y/o desarrolladores de TI (4). En la Figura 2-5 se encuentra el resumen de la clasificación de los posibles expertos.



**Figura 2-5.** Resumen Clasificación Posibles Expertos. Elaboración propia.

Los expertos son preseleccionados apoyándose en el biograma del experto (Cabrero & Barroso, 2013) dependiendo de su experticia profesional o académica relacionada con adopción de nuevas tecnologías, siendo preponderante *machine learning*. Los expertos son elegidos para continuar las siguientes fases si su puntaje supera los 70 puntos. Los criterios a analizar son: profesión, cargo, años de experiencia profesional en TI, años de experiencia profesional adoptando nuevas tecnologías, categoría docente, años como investigador con temas relacionados a tecnología, años como investigador con temas relacionados a adopción de tecnología, años como investigador en temas relacionados a adopción de nuevas tecnologías, años de experiencia relacionada a *machine learning*, número de investigaciones afines y número de publicaciones que hayan desarrollado sobre el tema. Estos criterios se resumen en la matriz visualizada en el Anexo A. Al aplicarse el biograma del experto a los candidatos, se generó como resultado la preselección de 27 expertos que obtuvieron un puntaje superior a 70 (Anexo B).



Posteriormente, a todos los candidatos preseleccionados, se les remite un cuestionario (Anexo C) para calcular el “coeficiente de competencia experta” (Cabrero & Barroso, 2013), el cual se obtiene a partir de la opinión mostrada por el experto sobre su nivel de conocimiento acerca del problema analizado, así como las fuentes que le permiten argumentar la respuesta ofrecida (Cabrero & Infante, 2014). Este coeficiente se expresa mediante la siguiente fórmula:

$$K = \frac{1}{2} (Kc + Ka)$$

Donde Kc (Coeficiente de conocimiento) se determina por medio de un factor (0,1) multiplicado por una autovaloración del experto dada en una escala del 0 al 10, el valor "0" representa el conocimiento nulo mientras que el "10" el pleno conocimiento de la problemática tratada. Por otro lado, Ka (Coeficiente de argumentación) se determina a partir de la suma de la puntuación alcanzada en una serie de parámetros valorando el grado de influencia de su experticia (por ejemplo: análisis teóricos realizados por el experto, experiencia obtenida en su actividad práctica, estudio sobre el tema objeto de investigaciones de autores de su nacionalidad, estudio sobre el tema objeto de investigaciones de autores extranjeros, su conocimiento acerca del problema de estudio en el extranjero, su intuición sobre el tema abordado, entre otros). Esta puntuación se obtiene a través de la calificación que el experto da en cada factor en una escala de alto, medio o bajo, la cual se pondera en una tabla paramétrica (García & Lena, 2018).

En esta investigación, el cálculo del coeficiente de argumentación se determina utilizando la ponderación de los factores de fundamentación en función del grado de influencia, discriminada en la Tabla 2-2, basada en la que realizó García & Lena (2018) en su investigación.

Este formulario fue contestado por once candidatos, de los cuales diez obtuvieron un valor de aceptación (K) de 0,7, quienes fueron seleccionados como los expertos para continuar con la fase de iteraciones, de los cuales seis (6) son académicos orientados a inteligencia artificial, dos (2) son académicos orientados a gerencia de TI y dos (2) profesionales gerentes, líderes, analistas y/o desarrolladores de TI. El resumen de los resultados del coeficiente experto se muestra en la Tabla 2-3.

**Tabla 2-2.** Ponderación de los factores de fundamentación en función del grado de influencia.

	Bajo		Medio		Alto	
	AP	AA	AP	AA	AP	AA
Experiencia obtenida a través de su actividad y práctica	0,2	0,04	0,4	0,08	0,5	0,1
Conocimiento sobre el estado de la cuestión a nivel nacional e internacional	0,08	0,08	0,16	0,16	0,2	0,2
Intuición sobre el tema abordado y conocimiento sobre tecnología	0,08	0,08	0,16	0,16	0,2	0,2
Estudio de trabajos y publicaciones sobre el tema	0,04	0,2	0,08	0,4	0,1	0,5

AP: ámbito profesional. AA: ámbito académico.

**Tabla 2-3.** Evaluación del coeficiente de competencia experta de los candidatos.

Nombre	Factor (ka)	Kc	Ka	K
Experto 1	AA	0,8	0,96	0,88
Experto 2	AA	0,8	0,8	0,8
Experto 3	AA	0,55	0,98	0,765
Experto 4	AA	0,75	0,96	0,855
Experto 5	AA	0,75	0,98	0,865
Experto 6	AA	0,85	1	0,925
Experto 7	AA	0,3	0,76	0,53
Experto 8	AA	0,7	0,8	0,75
Experto 9	AA	0,8	0,96	0,88
Experto 10	AP	0,6	0,8	0,7
Experto 11	AP	0,65	0,94	0,795

### 2.2.3 Ejecución de Rondas de Consulta

En esta fase se abstrae la información de los expertos y se trata de llegar a un consenso en las respuestas dadas por ellos. En una primera instancia se realiza una etapa exploratoria (**primera iteración**) mediante un primer cuestionario, en el cual se consulta a los expertos para obtener la perspectiva de cada uno sobre la cuestión de la investigación, con la finalidad de definir el terreno donde se encuentra cada uno y elaborar el siguiente cuestionario. La pregunta de este cuestionario es:

Teniendo en cuenta su experiencia profesional y académica (Investigaciones, desarrollo de proyectos y/o estudios académicos) ¿Cuáles factores y por qué considera usted que influyen en la adopción de machine learning? Si considera que ese factor es específico para una aplicación o algoritmo en especial de machine learning relacionar esa especificidad.

Las respuestas suministradas por los expertos se agrupan en términos semejantes, generando un listado de factores que fueron considerados influyentes en la adopción de *machine learning*; mediante un segundo cuestionario (**segunda iteración**) se pretende conocer la opinión de los pares expertos acerca de estos factores. En un primer apartado se solicita calificar que tan de acuerdo está con cada factor recopilado en el instrumento anterior. Posteriormente, se solicita que mencione si después de conocer la opinión de los demás considera que hay algún otro factor influyente.

Los resultados son analizados a través de estadísticos de tendencia central como la mediana (Me) y de posición como los cuartiles (Q1, Q2 y Q3). Estos permiten revelar información acerca de la distribución de las respuestas del grupo de especialistas. Asimismo, se emplean medidas de dispersión como el rango intercuartílico (RI) y la desviación típica (s) (Eslava, Cuadrado, & García, 2010).

Como criterio de medida del grado de convergencia, de proximidad o consenso se establece el rango intercuartílico relativo (RIR). El RIR revela el grado de dispersión de las respuestas y se determina de la siguiente manera:  $RIR = (Q3 - Q1)/Me$ . De esta forma, si  $RIR \leq 0,5$ , se considera que existe consenso. En concreto, el grado de consenso de las estimaciones individuales se alcanza cuando las opiniones presentan un rango intercuartílico bajo (Eslava et al., 2010). En una escala de niveles de consenso se establece: alto consenso cuando  $RIR \leq 0,2$ , consenso aceptable para  $0,2 > RIR \leq 0,5$ , y consenso bajo para  $RIR > 0,5$ .

Posteriormente se realiza un último cuestionario (**tercera iteración**) el cual se divide en tres partes. En primer lugar teniendo en cuenta el grado de consenso obtenido en la segunda iteración, se construye un cuestionario el cual pretende lograr una convergencia en si determinados factores son influyentes o no en la adopción de machine learning. En segundo lugar, se desea cuantificar el grado de influencia que tienen los factores identificados a través de las iteraciones anteriores. En tercer lugar, se realiza una

asociación de los factores agrupados por los expertos y los encontrados en la RSL, con el fin de determinar cuáles factores no fueron mencionados por los expertos, y del mismo modo, cuantificar el grado de influencia de estos. Para el cálculo del grado de influencia se realiza un promedio aritmético de la calificación de los expertos en cada factor en específico.

#### **2.2.4 Resultados**

En esta última fase se analizan los resultados obtenidos de la última iteración, obteniendo grados de consenso e importancia (Reguant & Torrado, 2016). De esta forma poseer los insumos para posteriormente realizar una propuesta del modelo que explique la intención de uso de *machine learning*.

### **2.3. Validación Modelo**

Teniendo en cuenta lo encontrado en la literatura y expuesto por los expertos se construye un modelo que explique la adopción de ML. Un modelo explicativo es un modelo construido con el propósito de comprobar las hipótesis causales que especifiquen cómo y por qué cierto fenómeno empírico ocurre (Shmueli & Koppius, 2011). Este modelo es validado luego a través de un instrumento aplicado a tomadores de decisiones de empresas colombianas.

#### **2.3.1 Modelo**

El modelo construido se basa en un modelo de ecuaciones estructurales (SEM), el cual es un método confirmatorio utilizado para probar los supuestos teóricos con datos empíricos (Haenlein & Kaplan, 2004), examinando cada relación propuesta desde una perspectiva teórica para asegurarse que los resultados sean conceptualmente válidos (Hair, Anderson, Tatham, Black, & others, 1999). Este tipo de modelo consta de un conjunto de variables dependientes, independientes e intermedias que se relacionan entre sí y pueden ser presentadas mediante un diagrama (Ramirez-Anormaliza et al., 2017).

Los modelos SEM contienen dos elementos, un modelo de medida que muestra las relaciones entre las variables latentes (representadas por elipses) y sus indicadores (variables observables representadas por rectángulos); y un modelo estructural que es la parte del modelo completo que propone relaciones entre las variables latentes (Martínez &

Fierro, 2018; Ramirez-Anormaliza et al., 2017). Estas relaciones reflejan las hipótesis sustantivas basadas en las consideraciones teóricas (Gefen, Straub, & Boudreau, 2000).

Dentro del modelo de medida existen dos tipos, un modelo formativo y uno reflectivo. En el primero cada indicador representa una dimensión del significado de la variable latente; eliminar un indicador significa que la variable pierde parte de su significado; en el segundo, los indicadores de la variable latente son competitivos entre sí y representan manifestaciones de la variable latente, por lo tanto, la eliminación de un indicador no afecta el significado de la variable latente. La relación causal va de la variable latente a los indicadores y un cambio en aquella será reflejado en todos sus indicadores (Gefen et al., 2000; Martínez & Fierro, 2018). Según Henseler (2017), se elige el modelo dependiendo la naturaleza del constructo, para efectos de esta investigación el modelo de medida construido es de tipo reflectivo, puesto que el constructo es de tipo comportamental, basado en actitudes y percepciones.

### **2.3.2 Instrumento**

Con la finalidad de validar el modelo en empresas colombianas, se desarrolla un cuestionario virtual en Google Forms. El cuestionario se divide en cinco secciones para facilitar la lectura y captar mayor atención de respuesta: 1) información demográfica, 2) factores técnicos, 3) factores externos, 4) factores organizacionales, 5) intención de uso y uso. En el Anexo D se encuentra el cuestionario completo que se remitió a 282 encargados de TI o innovación de diferentes empresas colombianas, con una tasa de respuesta de aproximadamente el 26%.

Las preguntas demográficas están relacionadas al sector económico, años de la empresa y cargo en la empresa de la persona encuestada. En cuanto a las preguntas para recoger la percepción de los diferentes constructos encontrados, se utiliza una escala Likert de cinco puntos donde 1 representa estar totalmente en desacuerdo con la afirmación, mientras que 5 indica estar totalmente de acuerdo. Como referencia para implementar las afirmaciones basadas en los constructos de modelos ya existentes, se utilizó a Cabrera & Villarejo (2018) debido a que en su investigación hacen una adaptación a un entorno de adopción de una tecnología por parte de una organización y no a nivel personal. Agregado a esto, se incluyeron unas variables resultantes de la literatura y del método Delphi.

Este cuestionario fue sometido a retroalimentación por parte de tres expertos, un académico orientado a inteligencia artificial, una académica orientada a gerencia de TI y una profesional de TI, quienes aprobaron el mismo, realizándose ajustes correspondientes que estuvieron acorde con lo encontrado a través de la presente investigación.

Para encontrar la población a encuestar se realizó una búsqueda por medio de la plataforma LinkedIn utilizando los filtros de país: Colombia; y por cargos como: Director TI, Director Innovación Tecnológica, Chief TI, Innovation Chief, Manager TI, Data Head, Data Lead, entre otros; a estas personas se les envió una invitación de contacto. Una vez generado el contacto de primer nivel, se remite inmediatamente la encuesta virtual en espera de respuesta.

Se recibieron un total de 73 respuestas de empresas Colombianas. Dentro de la trayectoria de estas encontramos diversidad, entre empresas jóvenes, desde un año de constitución, hasta empresas bastante maduras (más de cien años). En cuanto al tamaño de las empresas encontramos que más del 50% son grandes, la mayoría están ubicadas dentro del sector económico de servicios (89%), con mayor proporción de empresas de información y comunicaciones (38% del total) y de actividades financieras y de seguros (33% del total). La Tabla 2-4 muestra el detalle de la información demográfica de las empresas encuestadas en Colombia y en la

Tabla 2-5 el detalle de la sub-clasificación de las empresas de servicio.

En cuanto a la persona encuestada de cada empresa, aproximadamente el 74% poseen un cargo directivo superior, sin embargo, hay que tener en cuenta que en microempresas, o empresas pequeñas, cargos que en empresas grandes serían medios, en estas son de alta dirección. En la Tabla 2-6 se puede detallar los cargos encuestados.

**Tabla 2-4.** Información demográfica general Colombia.

	<b>Categoría</b>	<b>N°</b>	<b>%</b>
Años de existencia	0 – 10	25	34,25%
	11 – 25	16	21,92%
	26 – 50	13	17,81%
	51 – 100	16	21,92%
	> 100	3	4,11%
Tamaño Empresa	Microempresa	12	16,44%
	Pequeña	10	13,70%
	Mediana	8	10,96%
	Grande	43	58,90%
Sector Económico <sup>1</sup>	Servicios	65	89,04%
	Manufacturas	3	4,11%
	Administración pública	4	5,48%
	Suministro de electricidad, gas, vapor y aire acondicionado	1	1,37%
TOTAL		73	100%

**Tabla 2-5.** Sub-clasificación de empresas de servicios en Colombia.

<b>Sub-Categoría</b>	<b>N°</b>	<b>% Servicios</b>	<b>% Total</b>
Información y comunicaciones	28	43,08%	38,36%
Actividades financieras y de seguros	24	36,92%	32,88%
Comercio al por mayor y al por menor	5	7,69%	6,85%
Otras actividades de servicios	4	6,15%	5,48%
Servicios sociales y de salud	3	4,62%	4,11%
Transporte y almacenamiento	1	1,54%	1,37%
TOTAL	65	100,00%	89,04%

**Tabla 2-6.** Cargo persona encuestada por empresa.

<b>Categoría</b>	<b>N°</b>	<b>%</b>
Chief / Director / Gerente / Manager	118	61,14%
Head / Jefe / Lead / Líder	47	24,35%
Consultor / Arquitecto	15	7,77%
Vicepresidente	7	3,63%
Dueño	4	2,07%
TOTAL	163	100,0%

Ya consolidadas las respuestas, se realiza un tratamiento a los datos de la información referente a la percepción de los constructos, con el fin de generar los insumos para un análisis estadístico multivariado por medio de un modelo de ecuaciones estructurales por

<sup>1</sup> La categorización se hizo con base a la Clasificación Industrial Internacional Uniforme (CIIU) (OCDE, 2011) agrupando todas las empresas de servicios en la categoría "Servicios".

el método de mínimos cuadrados parciales (PLS-SEM). Para realizar el análisis se utilizó el software estadístico SmartPLS 3.3.2.

### 2.3.3 PLS-SEM

PLS-SEM (*Partial Least Squares - Structural Equation Modeling*), en español, mínimos cuadrados parciales en modelo de ecuaciones estructurales, es una técnica de análisis multivariante cuya finalidad es probar modelos estructurales; aunque fue desarrollada desde hace varias décadas, se considera una técnica emergente (Martínez & Fierro, 2018). Es particularmente apropiado cuando hay muchas variables manifiestas y latentes, en los que todas o algunas de las variables manifiestas son categóricas, donde las distribuciones no son normales y en condiciones de heterocedasticidad (Ziersch, Baum, Macdougall, & Putland (2005), citado en Ramirez-Anormaliza et al., 2017).

A pesar que una de las características de PLS-SEM es los tamaños pequeños de muestra (Yazdi, Motallebzadeh, Ashraf, & Baghaei, 2017), Marcoulides y Saunders (2006) sugieren que el tamaño mínimo de muestra dependa del número de relaciones entre constructos (variables latentes) que se especifiquen en el modelo (Citado en Martínez & Fierro, 2018). Sin embargo, esto no significa que el objetivo sea cumplir el requisito mínimo de tamaño de muestra, simplemente es un umbral para potencializar los resultados (Martínez & Fierro, 2018).. En la Tabla 2-7 se observa el número de la muestra sugerido con respecto al número de relaciones en el modelo estructural. En la presente investigación se establecieron un total de siete relaciones, por lo que sugiere un número de muestra superior a 80, según Marcoulides y Saunders (2006, Martínez & Fierro, 2018).

**Tabla 2-7.** Número de muestra sugerido (Marcoulides y Saunders, 2006, citado en Martínez & Fierro, 2018).

Número de relaciones en el modelo estructural	2	3	4	5	6	7	8	9	10
Número mínimo de la muestra	52	59	65	70	75	80	84	88	91

El análisis realiza una evaluación en dos etapas: en la primera se debe analizar la evaluación de viabilidad y la validez del modelo de medida; y en la segunda, la evaluación del modelo estructural (Yazdi et al., 2017). Esto se realiza para validar primero correcta



fiabilidad de los indicadores y de los constructos, en dado caso que no se presente se suele eliminar la variable en conflicto para ajustar el modelo de medida (Martínez & Fierro, 2018).

- **Confiabilidad y validez del Modelo de Medida**

La confiabilidad y validez del modelo de medida se determina a través de la validez convergente y la validez discriminante. Los modelos de medida reflexivos incluyen confiabilidad compuesta para evaluar lo que se denomina la validez convergente (J. Hair, Hult, Ringle, & Sarstedt, 2014), la cual es definida como el grado en el cual un indicador se correlaciona positivamente con indicadores alternativos del mismo constructo (Grandon et al., 2018), por otro lado, la validez discriminante indica el grado en el cual un constructo es verdaderamente diferente de otro (Ramirez-Anormaliza et al., 2017).

Dentro de la validez convergente se evalúa la fiabilidad del constructo (alfa de Cronbach y fiabilidad compuesta) y la varianza media extraída (AVE), y adicionalmente la fiabilidad individual de los indicadores:

- La fiabilidad del constructo o consistencia interna determina si los ítems que miden un constructo son similares en sus puntuaciones (Ramirez-Anormaliza et al., 2017), se sugiere que los valores del alfa de Cronbach y fiabilidad compuesta superen el 0,7, considerando el constructo con un nivel de fiabilidad adecuado (Cabrera & Villarejo, 2018; Joe F. Hair, Ringle, & Sarstedt, 2011; Ramirez-Anormaliza et al., 2017).
- El AVE indica que un conjunto de indicadores representan a un único constructo subyacente (Martínez & Fierro, 2018). Mide que la varianza del constructo se pueda explicar a través de los indicadores elegidos (Fornell & Larcker, 1981). Se recomienda un  $AVE \geq 0,50$ , que significa que cada constructo explica al menos el 50% de la varianza de los indicadores asignados (Fornell & Larcker, 1981; Grandon et al., 2018; Ramirez-Anormaliza et al., 2017).
- La fiabilidad individual de los indicadores reflectivos es valorada examinando las cargas factoriales o correlaciones simples, de las medidas o indicadores con su respectivo constructo (Ramirez-Anormaliza et al., 2017). Se consideran cargas adecuadas mayores a 0,7 (Cabrera & Villarejo, 2018; Grandon et al., 2018), por lo tanto, se sugiere que indicadores con cargas menores a este rango deben ser eliminados (Hair et al., 2011). Cuando un indicador tenga una carga menor al indicado, este podrá ser

eliminado y nuevamente correr el modelo para estimar los resultados (Urbach & Ahlemann, 2010).

En cuanto a la validez discriminante se utiliza el análisis de cargas cruzadas y el criterio de Fornell & Larcker (1981):

- Para el criterio de cargas cruzadas se debe visualizar que ningún indicador debe tener mayor valor de carga sobre otro constructo que sobre aquel que trate medir (Ramirez-Anormaliza et al., 2017).
- Con relación al criterio de Fornell & Larcker (1981) se establece que la raíz cuadrada del AVE de cada constructo debe ser mayor que la correlación más alta con otro constructo. Los elementos en la diagonal 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 (Ramirez-Anormaliza et al., 2017).

- **Validez del Modelo Estructural**

El análisis del modelo estructural se basa en el ajuste del modelo de medida para obtener las mejores estimaciones de los parámetros maximizando la varianza explicada de las variables latentes endógenas (Grandon et al., 2018). Para la valoración del modelo estructural se analizan los valores de los coeficientes de regresión estandarizados o coeficientes paths, valoración de los tamaños de los efectos, valoración del coeficiente de determinación y valoración de la relevancia predictiva (Martínez & Fierro, 2018; Ramirez-Anormaliza et al., 2017).

Los coeficientes paths señalan la intensidad de la relación entre las variables dependientes e independientes (Cabrera & Villarejo, 2018). Se analiza el signo algebraico, la magnitud y la significación estadística mediante los valores de la t-Student y p-values (Ramirez-Anormaliza et al., 2017). Aquel path cuyo signo sea contrario al signo postulado en la hipótesis, conducirá a inferir que ésta no sea soportada (Ramirez-Anormaliza et al., 2017). En cuanto a la magnitud, mayores valores absolutos denotan mayores relaciones (predictivas) entre constructos; cuanto más cercano a cero es el valor, más débil es la relación (Ramirez-Anormaliza et al., 2017). Se considera un path estadísticamente significativo si su valor es mayor a 0,1 (Yazdi et al., 2017).

Para la significación estadística mediante T-Statistics y P-value, se usa una técnica de remuestreo no paramétrica, llamada bootstrapping, parametrizada con 5000 muestras para calcular la fiabilidad de los coeficientes paths en las relaciones hipotetizadas. Las submuestras se generan con observaciones tomadas al azar del conjunto original de datos, que luego se utilizan para estimar el modelo de mínimos cuadrados parciales (PLS) (Palma, González, & Cortés, 2019).

Usando la distribución T-Student con  $n=5000$  de dos colas se obtienen como valores umbral para un nivel de significancia muy alto  $t(0,001; 4999) = 3,29$ ; alto  $t(0,01; 4999) = 2,58$ ; moderado  $t(0,05; 4999) = 1,96$  y bajo  $t(0,1; 4999) = 1,64$  (Martínez & Fierro, 2018; Yazdi et al., 2017). Por lo que respecta a los valores de p-value se consideran altos (\*\*\*) cuando  $p < 0,001$ , moderados (\*\*) cuando  $p < 0,01$  y bajos (\*) cuando  $p < 0,05$  (Ramirez-Anormaliza et al., 2017). En dado caso que un valor este debajo de un determinado umbral para t-tudent y superior a 0,05 para p-value se considera que la hipótesis en cuestión no se puede verificar (Martínez & Fierro, 2018; Palma et al., 2019).

La valoración de los tamaños de los efectos ( $f^2$ ) valora el grado con el que un constructo exógeno contribuye a explicar un determinado constructo endógeno en términos de  $R^2$  (Grandon et al., 2018). Una regla heurística de Cohen (1988) para evaluar  $f^2$  sostiene que:  $0,02 \leq f^2 < 0,15$ , 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. Una hipótesis debería ser rechazado si no produce un  $f^2$  significativo (Citado en Ramirez-Anormaliza et al., 2017).

Por otro lado, el coeficiente de determinación ( $R^2$ ) representa una 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. Los valores de  $R^2$  oscilan entre 0 a 1; cuanto más alto es el valor, más capacidad predictiva tiene el modelo para dicha variable (Ramirez-Anormaliza et al., 2017). Se clasifica un poder explicativo sustancial cuando el valor  $R^2$  es mayor a 0,75, moderado cuando  $R^2 > 0,5$  y débil cuando  $R^2 > 0,25$  (Joe F. Hair et al., 2011).

En cuanto a valoración de la relevancia predictiva, se realiza la prueba de Stone-Geisser de la medida de redundancia con validación cruzada ( $Q^2$ ), que indica la relevancia predictiva de las variables latentes y se puede calcular utilizando el procedimiento *blindfolding* en SmartPLS (Palma et al., 2019). Según Chin (1998), los valores superiores

a cero implican que las variables independientes tienen relevancia predictiva para la variable dependiente considerada, donde  $Q^2 > 0,02$  representa un tamaño del efecto pequeño,  $Q^2 > 0,15$  representa un tamaño del efecto medio, y  $Q^2 > 0,35$  representa un tamaño del efecto de altamente predictivo (Citado en Ramirez-Anormaliza et al., 2017).

### **3. Marco Conceptual**

En el presente capítulo se detalla el marco conceptual sobre el cuál se basa la investigación, en primer lugar, se realiza una descripción de qué es adopción de tecnología. En segundo lugar, se relaciona qué es un modelo de adopción y se vislumbran los modelos más trabajados en la literatura TAM y UTAUT. En tercer lugar, se hace una descripción de la tecnología enmarcada: *machine learning*. Por último, se exponen los factores encontrados en la literatura que influyen en la adopción de esta tecnología.

#### **3.1. Adopción de Tecnologías**

La adopción se define como la etapa de difusión de la tecnología en la cual una organización o individuo decide seleccionar una tecnología para su uso (Kaldi, Aghaie, & Khoshalhan, 2008). También se ha definido como la fase de exploración, investigación, deliberación y toma de decisiones (por parte de una firma, división o departamento) para introducir un nuevo sistema en la organización (Bouwman, van den Hooff, van de Wijngaert, & van Dijk, 2005). Las decisiones de adopción de innovaciones se diferencian de otros tipos de toma de decisiones por la novedad relativa de estas innovaciones y la mayor incertidumbre asociada a este tipo de decisión (López-Bonilla & López-Bonilla, 2011). Como referencia para esta investigación se considera la adopción de tecnología como la toma de decisión en implementar dicha tecnología, relacionándola con la intención de uso de la misma.

Debido a la evidencia que sugiere la existencia de una relación positiva entre la incorporación de tecnologías innovadoras y el desempeño de las empresas, ha cobrado especial relevancia analizar cuáles son los factores que afectan dicho proceso (Alderete, Jones, & Morero, 2014). De este modo, conocer las motivaciones y factores que

promueven la adopción de las TIC ha constituido un objetivo tanto de investigadores como de hombres de negocios (Chow, 1967, citado en Alderete et al., 2014).

### 3.2. Modelos de Adopción de Tecnologías

Se han propuesto varios modelos para estudiar la aceptación de los usuarios y la adopción de nuevas tecnologías de la información (Pearson & Grandon, 2006). Algunos de estos modelos se basan en la difusión de la teoría de la innovación (DOI) (Rogers, 2003), la teoría de la acción razonada (TRA) (Flanders, Fishbein, & Ajzen, 1975), el modelo de aceptación tecnológica (TAM) (Davis, 1989) y la teoría unificada de aceptación y uso de tecnología (UTAUT) (Venkatesh et al., 2003). Dentro de los más utilizados se encuentran el TAM y UTAUT (Grandon et al., 2018), los cuales son descritos a continuación.

El Modelo de Aceptación de la Tecnología (TAM), fue diseñado para realizar medidas evaluadoras de la calidad de los sistemas de información y de su adaptación a las necesidades del trabajo y, por lo tanto, se utiliza para hacer predicciones de aceptación y uso de nuevas tecnologías (López-Bonilla & López-Bonilla, 2011); TAM parte de la premisa que, mediante el análisis, se puede inferir si una sociedad está más predispuesta a incorporar novedades o, si por el contrario, es conservadora. Se trata, de una herramienta que sirve para conocer las expectativas de una sociedad al respecto de lo que aporta una tecnología (Christopher, Payne, & Ballantyne, 1994).

La teoría del modelo TAM se encuentra constituida y fundamentada en dos variables, la utilidad percibida y la facilidad de uso percibida (Latorre & Tovar, 2019), en la Figura 3-1 se ve la representación del modelo.

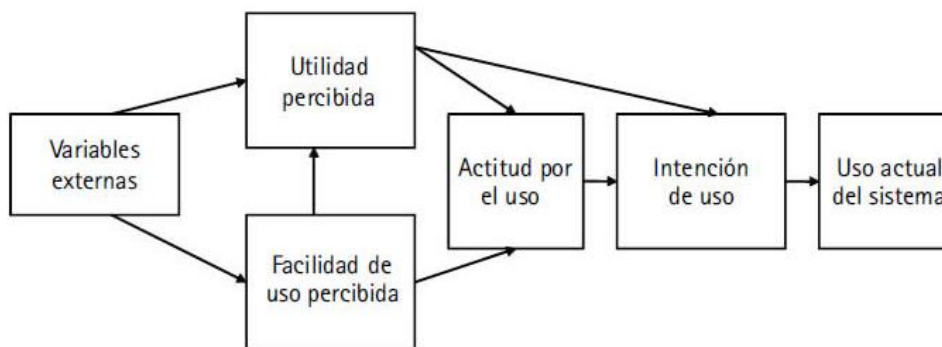
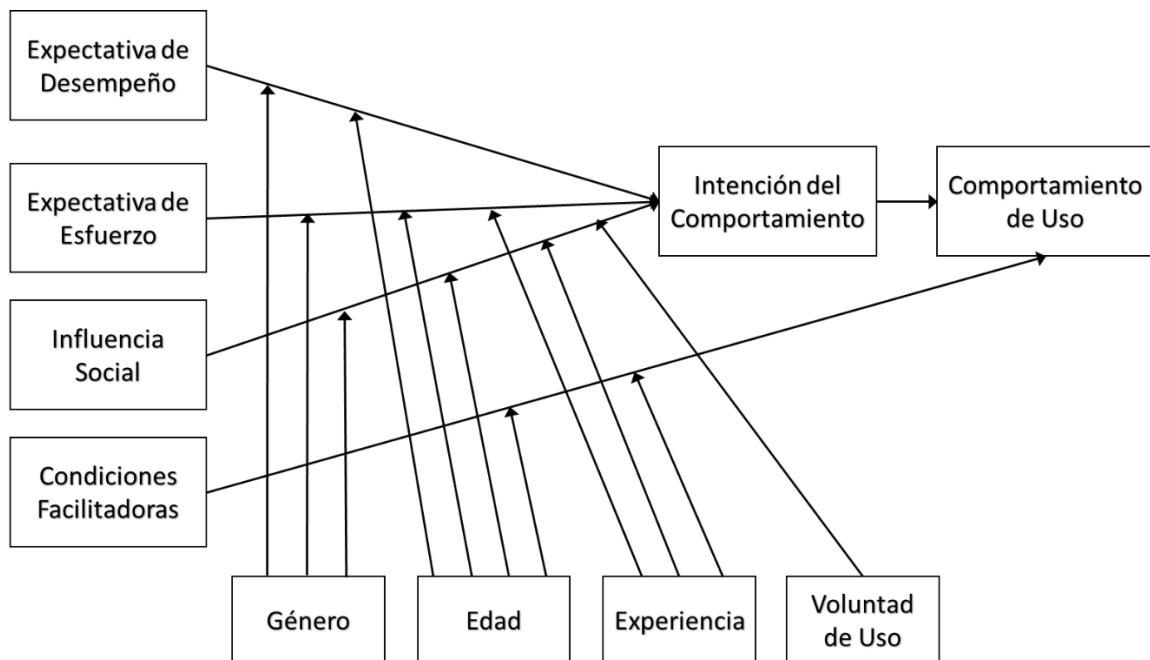


Figura 3-1. Modelo de aceptación tecnológica (TAM) (Davis, 1989).

Por otro lado, la teoría unificada de aceptación y uso de tecnología (UTAUT) nació de la necesidad de reunir las aportaciones de teorías anteriores sobre adopción de TI, entre las cuales se encuentra TAM y TRA (De León Sigg et al., 2014). En los años transcurridos desde su introducción, ha sido ampliamente empleada como estructura teórica en estudios empíricos sobre adopción y difusión de tecnologías por parte de investigadores en todo el mundo (Ramírez-Correa, Grandón, & Painén-Aravena, 2017). En la Figura 3-2 se ve la representación gráfica de este modelo.

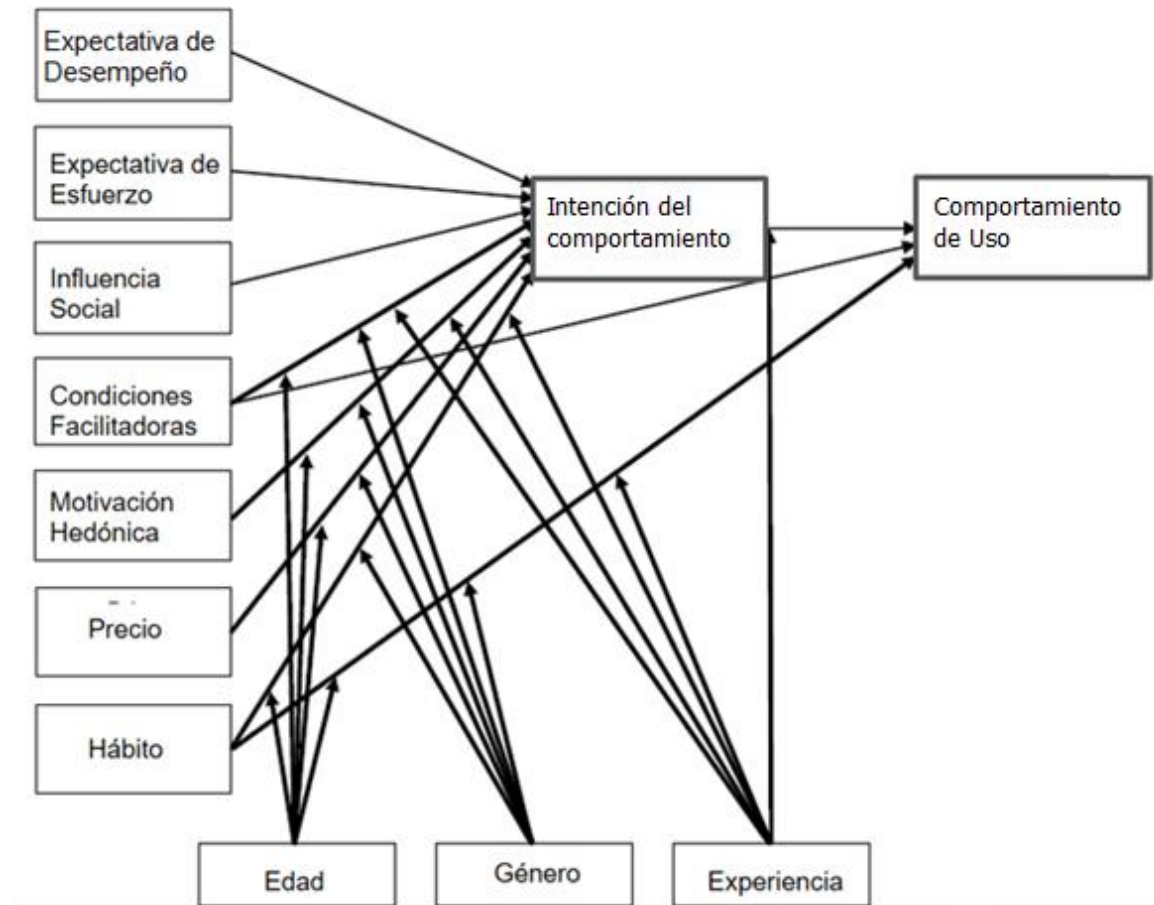


**Figura 3-2.** Teoría Unificada de aceptación y uso de la tecnología (Venkatesh et al., 2003).

UTAUT está conformada por cuatro constructos que explican potencialmente la intención de adoptar tecnología: expectativa de desempeño, expectativa de esfuerzo, influencia social y condiciones facilitadoras (Grandon et al., 2018). La expectativa de desempeño es tomada como la creencia que se tiene de que una tecnología ayude a conseguir una mejora en el desempeño de una tarea o proceso (Lima-Faria, Giuliani, Cavazos-Arroyo, & Kassouf-Pizzinatto, 2016); está fuertemente basada en la utilidad percibida de TAM (Fernández, 2015). La expectativa de esfuerzo se refiere al grado de facilidad o dificultad, que se considera asociado a la utilización de determinada tecnología (Lima-Faria et al., 2016); este constructo se basa en la facilidad de uso de TAM (Fernández, 2015). La influencia social se define como el grado en que se percibe que los demás le ven como consecuencia de utilizar la tecnología (Grandon et al., 2018). Finalmente, las condiciones facilitadoras corresponden al grado en que se considera que se dispone de la

infraestructura técnica y organizativa que le apoye en el uso de una tecnología (Grandon et al., 2018).

En el 2012 nace una extensión del modelo UTUAT para estudiar la aceptación y uso de la tecnología en un contexto de consumo (UTAUT 2) (Venkatesh, Thong, & Xu, 2012). Este modelo intenta explicar en forma global por qué los individuos utilizan las tecnologías que tienen a su disposición (Arones, León Fernández, & Moquillaza Vizarrreta, s. f.). En la Figura 3-2 se ve la representación gráfica de este modelo.



**Figura 3-3.** Teoría Unificada de aceptación y uso de la tecnología extendido (Venkatesh et al., 2012).

Los constructos adicionales son: motivación hedónica, se refiere a la diversión o placer proporcionado al individuo debido al uso de la tecnología en cuestión (Lima-Faria et al., 2016). La inclusión de ese factor fue justificada por su importancia, en el contexto de consumo; la relación precio / valor, se refiere a los beneficios que los usuarios reciben de



la tecnología, en comparación con la inversión monetaria (Alfonso et al., 2003); y el hábito, se refiere a la automatización creada por el aprendizaje de algo, de esa forma se crea una preferencia por el uso de determinada herramienta (Lima-Faria et al., 2016).

### **3.3. *Machine Learning***

Dentro del paradigma de hacer que las máquinas piensen y se comporten como humanos, se encuentra el *machine learning*, una tecnología que ha sido considerada como potencial para las empresas (Endeavor & Everis, 2018; Studio SAP, 2018). *Machine learning*, máquina de aprendizaje o aprendizaje automático, es un subcampo de la ciencias de la computación y una rama de la inteligencia artificial, que permite que las computadoras aprendan y actúen como lo hacen los humanos, mejorando su aprendizaje a lo largo del tiempo de una forma autónoma, alimentándolas con datos e información en forma de observaciones e interacciones con el mundo real (Faggella, 2020; Russell, Norvig, & Gutiérrez, 1996). La idea principal es proporcionar datos a los algoritmos y luego usarlos para saber cómo hacer predicciones o guiar decisiones (Bishop, 2016).

Los inicios del *machine learning* se encuentran sobre los 50s, cuando Alang Turing plantea la habilidad de una máquina de mostrar un comportamiento inteligente similar al de un humano (Fuentes-Barassi, 2010). Posteriormente, Arthur Samuel, pionero en el campo de los juegos informáticos e IA, escribió el primer programa de aprendizaje informático para mejorar los movimientos y estrategias del juego de damas chinas (Cárdenas, 2018; Samuel, 1967). A raíz de esto, nacieron múltiples cuestionamientos y se generaron altas expectativas de lo que podría llegar a ser el *machine learning* (Arias et al., 2019). Sin embargo, la investigación de esta tecnología sufrió un estancamiento, conocido como AI-Winter (Agrawal, Gans, & Goldfarb, 2019), debido a recortes de financiación ya que no se percibían los beneficios esperados, limitaciones conceptuales y capacidad en las computadoras al carecer de suficiente memoria y/o potencia de procesamiento (Cárdenas, 2018; Teigens, s. f.). Si bien durante este periodo resultaron investigaciones esporádicas notables, fue hasta entrados los 2000 que se logró recuperar la reputación del campo y explotó de nuevo la investigación de la tecnología (Agrawal et al., 2019; Cárdenas, 2018; Teigens, s. f.), hasta el punto de hoy en día poseer herramientas como: el Kinect de Microsoft, capaz de detectar 20 articulaciones humanas, permitiendo a una persona interactuar mediante movimientos con una computadora (Osorio & Peña, 2015). El DeepFace de Facebook, capaz de reconocer o verificar individuos de una foto (Taigman,

Ming, Ranzato, & Wolf, 2014). El proyecto GoogleBrain, quienes han ayudado a patólogos a detectar cáncer mediante *machine learning*, o la herramienta de entender dibujos humanos básicos (Ha, 2017; Stumpe & Peng, 2017).

El potencial del *machine learning* en las empresas se ha descrito para áreas como servicio al cliente, marketing, entre otros (Teigens, s. f.). Por ejemplo:

- Se puede implementar clasificación automática de los casos de atención al cliente, lo que evita depender del agente de atención al cliente a la hora de tener que tomar una decisión y, por lo tanto, ahorra tiempo al agente (Salesforce, 2017).
- Enrutamiento automático de casos una vez que la llamada se ha clasificado automáticamente, el sistema ya puede reenviar la llamada al agente mejor calificado para determinar el tipo de problema (Salesforce, 2017).
- Recomendación de soluciones y bases de conocimiento, esto aumenta la productividad y la calidad de un servicio, al sugerir la solución con mayores probabilidades de resolver el problema del cliente (Cárdenas, 2018).
- Analizar a las personas que ya conoces: los usuarios de aplicaciones más valiosos o rentables que se tengan. Una vez identificados, se buscará otros perfiles similares, y al mismo tiempo, se buscará en lugares que de otro modo se podrían pasar por alto. Así, la herramienta ayuda a las empresas a encontrar fácilmente a los clientes más valiosos y captar su atención (Tw Google, 2018), entre otros.

Con aras de la investigación se adopta como definición, para que sea la base de partida tanto de los expertos como de los directivos que contesten las encuestas, la premisa dada por Bishop (2016) que machine learning es un conjunto de algoritmos para mapear datos, aprender de ellos y luego ser capaz de hacer una predicción o sugerencia sobre algo.

### **3.4. Factores de Adopción de *Machine Learning* a partir de la Literatura**

Si bien se conoce el potencial que el *machine learning* posee, se establece como desafío, encontrar qué factores pueden considerarse como influyentes en su adopción, y/o que modelos se han usado para estudiar estos. A través de la revisión sistemática de literatura

se encontraron cuatro artículos (Berge, 2018; Kanak & Sogukpinar, 2017; Kessler & Martin, 2017; Rana et al., 2014) que usaron modelos de adopción para estudiar inteligencia artificial y/o *machine learning*, resultando los modelos TAM (modelo de aceptación tecnológica), MOT (modelo de confianza) y UTAUT (teoría unificada de aceptación y uso de tecnología).

Adicionalmente, se encontraron en los quince artículos resultantes de la RSL un total de 46 factores que pueden influir en la adopción de *machine learning*: Riesgo Percibido / Fiabilidad (1), Confiabilidad / Integridad (2), Condiciones facilitadoras (3), Expectativa de desempeño (4), Expectativa de esfuerzo (5), Hábito (6), Influencia social (7), Precio / Valor (8), Relación con la tecnología (9), Seguridad de la data (10), Facilidad de uso percibida (11), Utilidad percibida (12), Confianza (13), Facilidad de uso percibida (14), Utilidad percibida (15), Adopción en otras industrias (16), Barreras percibidas (17), Competencia en ML (18), Disponibilidad de herramientas (19), Familiaridad con ML (20), Necesidad e importancia (21), Satisfacción con sistemas existentes (22), Usado por los competidores (23), Costos (24), Autonomía (25), Privacidad (26), Seguridad de la data (27), Interoperabilidad (28), Ejecución interpretada (29), Consumo de memoria (30), Experiencia con ML (31), Facilidad de uso (32), Funcionalidad (33), Necesidad (34), Soporte (35), Consumo de memoria (36), Credibilidad de la información (37), Marcos que faciliten el intercambio de datos (38), Políticas de gestión de datos (39), Eficiencia (40), Fiabilidad (41), Interpretabilidad (42), Seguridad de la data (43), Usabilidad (44), Poseer data training (45), Complejidad de entrenamiento (46). En el Anexo E se realiza un desglose de los factores encontrados con la descripción tomada del artículo tratado y una asociación al modelo que fue trabajado.

Puesto que hay factores similares o que pueden asociarse, se realiza una agrupación de estos factores resultando doce, muchos de ellos se aglomeraron a constructos trabajados en los modelos usados. En la Tabla 3-1 se puede observar la agrupación correspondiente.

**Tabla 3-1.** Agrupación de factores de adopción de *machine learning* encontrados en la literatura.

Factor Agrupado	Descripción original del factor (fuente)	Factor(es) (Número descrito en el Anexo E)	Artículo Relacionado (Número descrito en el Anexo E)
-----------------	--	--	--

Autonomía	Grado en que una persona cree que usar una tecnología estaría libre de esfuerzo (Huckvale, Wang, Majeed, & Car, 2019).	(25)	(7)
Condiciones facilitadoras	Grado en que una persona considera que dispone de la infraestructura técnica y organizativa que le apoye en el uso de una tecnología (Venkatesh et al., 2003).	(3) (19) (18) (20) (22) (28) (29) (31) (35)	(2)(4)(5)(6)(8)(9) (10)(11)
Factor Agrupado	Factor Agrupado	Factor Agrupado	Factor Agrupado
Confiabilidad / Integridad	La percepción que el administrador se adhiere a un conjunto de principios que el usuario considera aceptables (Mayer, Davis, & Schoorman, 1995).	(2) (37)	(1)(12)
Eficiencia	Grado en que una persona cree que usar una tecnología estaría libre de esfuerzo (Gao et al., 2018).	(30) (36) (40)	(9)(12)(13)
Facilidad de uso	Grado en que una persona cree que usar una tecnología estaría libre de esfuerzo (Davis, 1989).	(5) (11) (14) (32) (42) (44) (46)	(2)(3)(4)(5)(6)(10) (11)(13)(15)
Gestión de datos	Grado de calidad de los datos representada en planes, políticas, programas y/o prácticas que entregan, controlan, protegen e incrementan el valor de los datos a lo largo de su ciclo de vida (International & Brackett, 2015),	(10) (13) (15) (26) (27) (38) (39) (43) (45)	(2)(3)(7)(12)(13) (14)
Hábito	Grado en que las personas tienden a realizar conductas de forma automática debido al aprendizaje. (Venkatesh et al., 2003).	(6)	(2)
Influencia social	Grado en el que un individuo percibe que los demás valorarán la utilización del sistema (Venkatesh et al., 2003).	(7) (16) (23)	(2)(4)(5)(6)
Necesidad e importancia	Grado de necesidad e importancia de la información generada por la tecnología en una organización (Rakesh Rana, Staron, Hansson, Nilsson, & Meding, 2015).	(21) (34)	(4)(5)(6)(10)(11)
Precio / Valor	Compensación cognitiva del consumidor entre los beneficios percibidos de las aplicaciones y el costo monetario del uso de una tecnología. (Venkatesh et al., 2003).	(8) (24)	(2)(4)(5)(6)
Riesgo Percibido / Fiabilidad	La creencia de resultados o consecuencias positivas o negativas en nombre de factores contextuales no relacionados con el administrador (Mayer et al., 1995).	(1) (17) (41)	(1)(2)(13)

---

Utilidad	Grado en que una persona cree que usar un sistema en particular mejoraría su desempeño laboral (Davis, 1989).	(4) (9) (12) (15) (33)	(2)(3)(4)(5)(6)(10) (11)
----------	---	---------------------------	-----------------------------

---

Teniendo en cuenta que la investigación va destinada a encontrar factores que pueden influir la adopción de *machine learning* por parte de las empresas, se puede descartar el hábito de la agrupación anterior, puesto que está asociado a estudios de adopción de tecnología a nivel personal y no a nivel organizativo. De hecho, el artículo donde se hace mención está asociado a estudiar la adopción de robots de voz en personas del común (Kessler & Martin, 2017). De esta manera se puede inferir un total de **once** factores resultantes de la literatura.

## 4. Factores de Adopción a partir de Expertos (Aplicación Método Delphi)

Mediante el método Delphi se logra llegar a inferir trece factores de los cuales expertos han calificado que pueden influir en la adopción de *machine learning*. En la Figura 4-1 se puede observar un resumen del proceso de selección de los expertos y de las iteraciones.

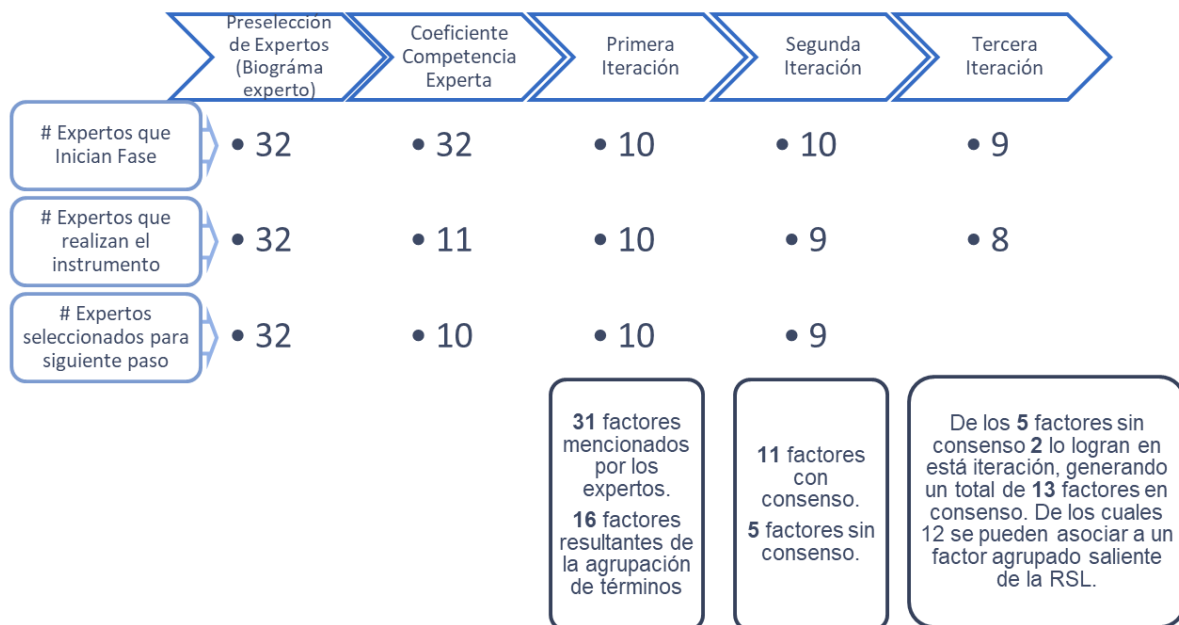


Figura 4-1. Resumen proceso Método Delphi. Elaboración propia.

En la **primera iteración** se remite el formulario a los diez expertos seleccionados, los cuales contestan en su totalidad exponiendo 31 posibles factores que influyen en la adopción de *machine learning*. En la Tabla 4-1 se observa la agrupación de los factores mencionados por los diez expertos, indicando el número de veces que fueron aludidos.

**Tabla 4-1.** Asociación de factores de adopción de *machine learning* mencionados por los expertos.

Factor Asociado	Factores Mencionados por los Expertos
<b>Apoyo de los directivos</b>	Apoyo de los directivos.
<b>Beneficios percibidos</b>	Beneficios percibidos, reconocer beneficios.
<b>Calidad de los datos</b>	Calidad de datos, calidad tratamiento datos (x2).
<b>Conocimientos de la materia</b>	Conocimiento de la materia (x3).
<b>Constante aprendizaje</b>	Constante aprendizaje.
<b>Constante evolución de las herramientas y/o algoritmos</b>	Constante evolución de las herramientas y/o algoritmos.
<b>Costos de adopción</b>	Presupuesto, costos (x2).
<b>Cultura de inversión</b>	Cultura de inversión.
<b>Disponibilidad de datos</b>	Acceso a datos, disponibilidad de datos (x4), volumen de datos.
<b>Facilidad de modelamiento del objetivo</b>	Facilidad de modelamiento del objetivo.
<b>Influencia social</b>	Influencia social.
<b>Infraestructura</b>	Asequibilidad de los equipos de cómputo, empresas no cuentan con la tecnología apropiada (tienen 2.0 o 3.0).
<b>Integridad de las herramientas TIC</b>	Integración con el resto de herramientas TIC.
<b>Objetivo muy bien definido</b>	Definición de objetivos, objetivos personalizados, objetivo muy bien definido.
<b>Posible ventaja competitiva</b>	Posible ventaja competitiva.
<b>Utilidad percibida</b>	Utilidad percibida.

En la **segunda iteración** se remite el formulario a los diez expertos nuevamente, de los cuales se obtiene respuesta de nueve. Al finalizar la ronda, se condensan las respuestas y se les aplica el análisis estadístico para encontrar el coeficiente de variación (RIR), en la Tabla 4-2 se resume este análisis, en donde se puede abstraer que once factores consiguen un consenso, seis en un nivel alto y cinco en un nivel aceptable. Asimismo, los factores constante aprendizaje, constante evolución de las herramientas y/o algoritmos, cultura de inversión, facilidad de modelamiento del objetivo e infraestructura, son los factores en donde su nivel de consenso es bajo, por lo que se debe preguntar de nuevo por estos en la siguiente iteración.

**Tabla 4-2.** Grado de consenso de los factores de adopción de *machine learning* mencionados por los expertos en la primera iteración.

Factor	ME	Q1	Q3	s	RIR	Nivel Consenso
Apoyo de los directivos	5	5	5	0,667	0	Alto consenso
Beneficios percibidos	5	4	5	0,882	0,2	Alto consenso
Conocimientos de la materia	5	4	5	0,882	0,2	Alto consenso
Costos de adopción	5	4	5	0,882	0,2	Alto consenso
Objetivo muy bien definido (¿Para qué se va a usar específicamente?)	5	4	5	0,882	0,2	Alto consenso
Posible ventaja competitiva	5	4	5	0,882	0,2	Alto consenso
Calidad de los datos	5	3	5	1	0,4	Consenso aceptable
Disponibilidad de datos	5	3	5	1	0,4	Consenso aceptable
Influencia social	5	3	5	1	0,4	Consenso aceptable
Integridad de las herramientas TIC	5	3	5	1,453	0,4	Consenso aceptable
Utilidad percibida	5	3	5	1,054	0,4	Consenso aceptable
Infraestructura	5	2	5	1,764	0,6	Bajo consenso
Constante aprendizaje	3	3	5	1,414	0,667	Bajo consenso
Constante evolución de las herramientas y/o algoritmos	3	3	5	1,054	0,667	Bajo consenso
Cultura de inversión	3	3	5	1,333	0,667	Bajo consenso
Facilidad de modelamiento del objetivo	3	3	5	1,054	0,667	Bajo consenso

Para la **tercera iteración** el formulario es remitido a los nueve expertos que respondieron en la iteración anterior, de los cuales contestan ocho. En la Tabla 4-3 muestra el resultado de la sección donde se trata de llegar a un consenso de los cinco factores anteriormente mencionados cuya opinión se encontraba dividida; los factores en los que se logra un consenso en esta iteración son Constante evolución de las herramientas y/o algoritmos y Facilidad de modelamiento del objetivo.

**Tabla 4-3.** Grado de consenso de los factores de adopción de *machine learning* que no lograron una convergencia en la segunda iteración.

Factor	ME	Q1	Q3	s	RIR	Nivel Consenso
Facilidad de modelamiento del objetivo	4,5	3,25	5	1,73	0,39	Consenso aceptable
Constante evolución de las herramientas y/o algoritmos	5	3	5	1,25	0,40	Consenso aceptable
Constante Aprendizaje	5	1	5	2,07	0,80	Bajo consenso
Infraestructura	5	1	5	2,07	0,80	Bajo consenso
Cultura de inversión	3	1	5	2,14	1,33	Bajo consenso



En cuanto a la cuantificación por parte de los expertos del nivel de influencia que poseen los once factores asociados mencionados por ellos y que consiguieron consenso en la segunda iteración y los dos factores que lo consiguieron en esta, se visualiza en la Tabla 4-4, en donde la puntuación máxima es cinco.

**Tabla 4-4.** Resultados cuantificación promedio del grado de influencia de los factores de adopción mencionados por los expertos, en la adopción de *machine learning*.

Factor	Puntuación promedio
Beneficios percibidos	4,75
Posible ventaja competitiva	4,75
Conocimientos de la materia	4,375
Disponibilidad de datos	4,375
Objetivo muy bien definido (¿Para qué se va a usar específicamente?)	4,375
Utilidad percibida	4,25
Costos de adopción	4,125
Apoyo de los directivos	4
Calidad de los datos	4
Constante evolución de las herramientas y/o algoritmos	4
Facilidad de modelamiento del objetivo	3,875
Integridad de las herramientas TIC	3,125
Influencia social	3

En la Tabla 4-5 se puede observar una asociación de los factores mencionados por los expertos que llegaron a consenso y los factores agrupados resultantes de la RSL, mediante términos similares y/o variables trabajadas dentro de los constructos globales resultantes de la RSL. De esta manera resultan cuatro factores agrupados abstraídos de la literatura que los expertos no mencionaron, y un factor que los expertos mencionaron y no se puede asociar a los factores agrupados de la literatura.

**Tabla 4-5.** Comparación factores de adopción de *machine learning* encontrados en la RSL y los mencionados por los expertos.

Factores de la RSL	Factores mencionados por los expertos
Autonomía	
Condiciones facilitadoras	Constante evolución de las herramientas y/o algoritmos, integridad de las herramientas TIC, conocimientos de la materia
Confiabilidad / Integridad	Calidad de los datos
Eficiencia	
Facilidad de uso	Facilidad de modelamiento del objetivo
Gestión de datos	Disponibilidad de datos
Influencia social	Influencia social
Necesidad e importancia	
Precio / Valor	Costos de adopción
Riesgo Percibido / Fiabilidad	
Utilidad	Beneficios percibidos, posible ventaja competitiva, objetivo muy bien definido (¿Para qué se va a usar específicamente?), utilidad percibida
Factor no mencionado en la literatura	Apoyo de los directivos

**Tabla 4-6.** Resultados cuantificación promedio del grado de influencia de los factores resultantes de la asociación de los mencionados por los expertos y los agrupados en la RSL, en la adopción de *machine learning*.

Factor	Grado de Influencia	Fuente Factor
Utilidad	4,53	RSL y Delphi
Gestión de datos	4,38	RSL y Delphi
Precio / Valor	4,13	RSL y Delphi
Confiabilidad / Integridad	4,00	RSL y Delphi
Apoyo de los directivos	4,00	Delphi
Facilidad de uso	3,88	RSL y Delphi
Condiciones facilitadoras	3,83	RSL y Delphi
Eficiencia	3,50	RSL
Necesidad e importancia	3,50	RSL
Riesgo Percibido / Fiabilidad	3,38	RSL
Influencia social	3,00	RSL y Delphi
Autonomía	2,75	RSL

En la Tabla 4-6 se aprecia la cuantificación por parte de los expertos, del grado de influencia que tienen los doce factores resultantes de la asociación anterior sobre la adopción de ML, en donde se distingue que la utilidad, la gestión de datos, el precio/valor, la confiabilidad e integridad y el apoyo de los directivos, según los expertos, son considerados los factores más influyentes en la adopción de *machine learning*. La mayoría de estos factores fueron mencionados, tanto por los expertos como en la literatura.

Finalmente, teniendo en cuenta la naturaleza de los factores asociados se realiza una categorización en factores externos, organizacionales y técnicos. En la Tabla 4-7 se resume esta categorización. Adicionalmente se enmarca cuáles fueron los factores que tienen como fuente tanto la RSL como el método Delphi, y el que no se logró asociar a la agrupación saliente de RSL, puesto que estos van a considerarse para la construcción del modelo.

**Tabla 4-7.** Categorización de factores de adopción de *machine learning* resultantes de la asociación del método Delphi y la RSL.

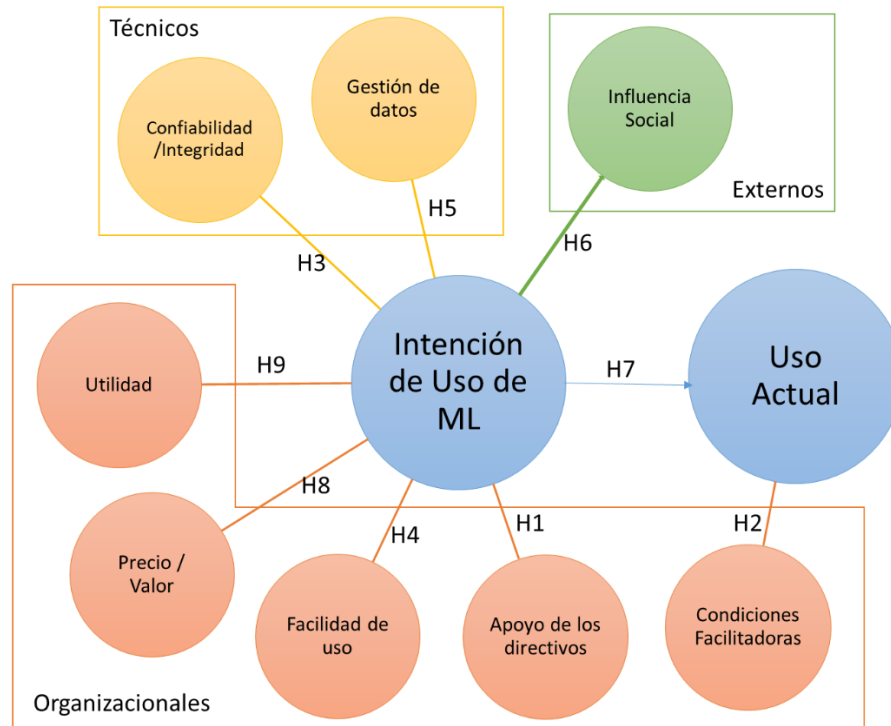
Factor	Fuente Factor	Tipo	Modelo teórico
Influencia social	RSL y Delphi	Externos	UTAUT
Condiciones facilitadoras	RSL y Delphi	Organizacionales	UTAUT
Facilidad de uso	RSL y Delphi	Organizacionales	TAM (expectativa de esfuerzo - UTAUT)
Precio / Valor	RSL y Delphi	Organizacionales	UTAUT
Utilidad	RSL y Delphi	Organizacionales	TAM (expectativa de desempeño - UTAUT)
Necesidad e importancia	RSL	Organizacionales	
Apoyo de los directivos	Delphi	Organizacionales	Extraído de los expertos
Confiabilidad / Integridad	RSL y Delphi	Técnicos	MOT
Gestión de datos	RSL y Delphi	Técnicos	DAMA
Autonomía	RSL	Técnicos	
Eficiencia	RSL	Técnicos	
Riesgo Percibido / Fiabilidad	RSL	Técnicos	

## **5. Modelo de Adopción de *Machine Learning***

Como base para la construcción de un modelo de adopción de *machine learning* se considera la asociación realizada entre lo inferido de los expertos y lo resultante de la RSL. Este modelo será validado en empresas colombianas, en el presente capítulo se describe la construcción de este modelo y los resultados de la validación realizada.

### **5.1. Construcción del Modelo de Adopción de *Machine Learning***

Para la construcción del modelo y sus respectivas hipótesis, se considera los siete factores que tienen como fuente tanto la RSL como el método Delphi: condiciones facilitadoras, confiabilidad e integridad, facilidad de uso, gestión de datos, influencia social, precio / valor y utilidad; y el que no se logró asociar a la agrupación saliente de RSL: apoyo a los directivos. Teniendo en cuenta que la mayoría de factores se asociaron a constructos del modelo UTAUT (Venkatesh et al., 2003), se toma como referencia para la construcción del modelo de la investigación actual; agregando los factores adicionales como constructos, resultando en total diez constructos. En la Figura 5-1 se observa el modelo que agrupa los factores de acuerdo con tres categorías: Organizacionales, Técnicos y Externos.



**Figura 5-1.** Modelo de adopción de *machine learning*. Elaboración propia.

A continuación se describe cada uno de los constructos trabajados:

### **Factores Organizacionales**

En este grupo se incluyen los constructos asociados a procesos visionales (procesos que ayudan a encaminar a la organización a sus expectativas futuras) y de apoyo de una organización (Cerón & Arboleda, 2018).

- **Apoyo de los directivos:** Constructo resultante de lo mencionado por los expertos, refiriéndose a la intención de estos en adoptar la tecnología y destinación de presupuesto por parte de la mesa directiva. La hipótesis relacionada a este constructo es:

**H1:** El apoyo por parte de los directivos (AD) se relaciona positivamente con la intención de usar (IU) *machine learning* por parte de empresas colombianas.
- **Condiciones facilitadoras:** Constructo traído desde la literatura, el cual forma parte de UTAUT. Además de los tres ítems validadores propuestos por Venkatesh (2003), se anexaron cuatro: “satisfacción con sistemas existentes”, encontrado en la literatura; “poseer tecnología para la gestión de datos”, “soporte previo proporcionado

por la academia” y “experiencia previa”, encontrados mediante el método Delphi. La hipótesis relacionada a este constructo es:

**H2:** La existencia de condiciones facilitadoras (CF) se relacionan positivamente con el uso actual (USO) de *machine learning* por parte de empresas colombianas.

- **Facilidad de Uso:** Constructo traído desde la literatura, asociado a la expectativa de esfuerzo de UTAUT. Complementado por los expertos mediante la adición de un ítem a los cuatro planteados en TAM (Davis, 1989): “facilidad en el modelamiento”. La hipótesis relacionada a este constructo es:

**H4:** La facilidad de uso (FU) se relaciona positivamente con la intención de usar (IU) *machine learning* por parte de empresas colombianas.

- **Precio / Valor:** Constructo perteneciente a UTAUT extendido y soportado por los expertos. Se consideran los tres ítems sugeridos por Venkatesh, Thong, & Xu (2012) y adoptados por Ramírez-Correa (2014). La hipótesis relacionada a este constructo es:

**H8:** La relación precio valor (PV) se relaciona positivamente con la intención de usar (IU) *machine learning* por parte de empresas colombianas.

- **Utilidad:** Constructo traído desde la literatura, asociado a la expectativa de desempeño de UTAUT. Se consideran los cinco ítems planteados en TAM (Davis, 1989) y adoptados por Cabrera & Villarejo (2018). La hipótesis relacionada a este constructo es:

**H9:** La utilidad (U) se relaciona positivamente con la intención de usar (IU) *machine learning* por parte de empresas colombianas.

### **Factores Técnicos:**

En este grupo se incluyen los constructos referentes a procesos misionales (conjunto procesos que cumplen con la razón de existencia de la organización), correspondientes a la operación de la organización (Cerón & Arboleda, 2018).

- **Confiabilidad e Integridad:** Constructo construido mediante lo encontrado en la literatura y complementado por los expertos. Se contempla: consistencia en la información proporcionada, significancia de la información generada, credibilidad de los resultados y confianza en la fuente de los datos. La hipótesis relacionada a este constructo es:

**H3:** La confiabilidad e integridad (C) se relaciona positivamente con la intención de usar (IU) *machine learning* por parte de empresas colombianas.

- **Gestión de Datos:** Constructo construido desde la literatura, infiriendo: políticas de seguridad de la data de insumo de los algoritmos, políticas de privacidad de la información resultante, protocolos de integridad de la información de los diferentes sistemas fuente y tecnologías para el procesamiento de la data de forma eficiente; y desde los expertos, obteniendo: disponibilidad de data suficiente para análisis y/o aprendizaje. Mediante la validación del instrumento por parte de expertos, se sugirió incluir una variable explicativa y preguntar sobre el nivel de digitalización que se considera que posee la empresa. La hipótesis relacionada a este constructo es:  
**H5:** La gestión de datos (GD) se relaciona positivamente con la intención de uso (IU) de *machine learning* por parte de empresas colombianas.

### **Factores Externos:**

En este grupo se incluye el constructo que comprende a factores que no pueden ser controlados dentro del contexto organizacional y/o técnico (De León Sigg et al., 2014).

- **Influencia Social:** Constructo traído desde la literatura trabajado en UTAUT y apoyado por los expertos. Se consideran los cuatro ítems sugeridos por Venkatesh (2003) y adoptados por Cabrera & Villarejo (2018). La hipótesis relacionada a este constructo es:  
**H6:** La influencia social (IS) se relaciona positivamente con la intención de usar (IU) *machine learning* por parte de empresas colombianas.

Finalmente, y siguiendo los modelos de intención de uso de la tecnología, se relaciona el siguiente constructo:

- **Intención de Uso:** Constructo trabajado en UTAUT como variable independiente con respecto a los demás constructos, a excepción del constructo de USO. Se consideran los tres ítems sugeridos por Venkatesh (2003). La hipótesis relacionada a este constructo es:  
**H7:** La intención de uso (IU) se relaciona positivamente con el uso actual (USO) de *machine learning* por parte de empresas colombianas.

## 5.2. Validación Modelo de Medida

Con la finalidad de determinar la validez convergente de los constructos se calculó el alfa de Cronbach, la confiabilidad compuesta y la varianza media extraída (AVE) de cada constructo. Los valores alfa superan el valor de 0,7, a excepción del constructo C (Confiabilidad e Integridad), mostrando alta consistencia interna de cada constructo, en especial las variables latentes FU (Facilidad de Uso), GD (Gestión de Datos), IU (Intención de uso) y USO; en cuanto al constructo C, a pesar de no superar el límite, si se encuentra muy cerca de éste, no obstante refleja que no es tan consistente internamente. Por otro lado, se valida la fiabilidad compuesta de todos los constructos debido a que superan el valor sugerido de 0,7. Por último, los valores AVE superan el umbral de 0,5, excepto nuevamente el constructo C, aun así, se encuentra muy cerca del límite. La Tabla 5-1 visualiza los valores de estos indicadores para cada constructo.

**Tabla 5-1.** Validez convergente.

	Alfa de Cronbach	Fiabilidad Compuesta	AVE
<b>AD</b>	0,89	0,95	0,90
<b>C</b>	0,69	0,77	0,48
<b>CF</b>	0,88	0,91	0,60
<b>FU</b>	0,92	0,94	0,76
<b>GD</b>	0,95	0,96	0,79
<b>IS</b>	0,79	0,83	0,55
<b>IU</b>	0,92	0,95	0,86
<b>PV</b>	0,81	0,89	0,72
<b>U</b>	0,86	0,90	0,65
<b>USO</b>	0,95	0,96	0,90

Al revisar las cargas individuales de cada ítem (Tabla 5-2) con respecto a cada constructo se puede observar que las variables C1, C4, CF3, CF5, IS2 e IS3 no superan el valor recomendado de 0,7, lo que significa que el ítem evaluador de la variable no fue comprendido por los encuestados colombianos o la variable no explica el constructo en Colombia.

**Tabla 5-2.** Cargas de las variables de cada constructo.

AD	C	CF	FU	GD	IS	IU	PV	U	USO
AD1 0,94	C1 0,58	CF1 0,77	FU1 0,76	GD1 0,90	IS1 0,76	IU1 0,95	PV1 0,79	U1 0,90	USO1 0,93
AD2 0,95	C2 0,95	CF2 0,90	FU2 0,90	GD2 0,85	IS2 0,68	IU2 0,89	PV2 0,87	U2 0,71	USO2 0,94
	C3 0,71	CF3 0,67	FU3 0,91	GD3 0,89	IS3 0,57	IU3 0,93	PV3 0,88	U3 0,85	USO3 0,97
	C4 0,40	CF4 0,79	FU4 0,87	GD4 0,90	IS4 0,91			U4 0,82	
		CF5 0,47	FU5 0,90	GD5 0,92				U5 0,73	
		CF6 0,85		GD6 0,89					
		CF7 0,88							



Al analizar los ítems evaluadores en cuestión se determina:

- C1 - La información proporcionada por los algoritmos de ML debe ser consistente: el ítem debería cuestionar si la información es consistente actualmente y no un deber ser, por lo que los encuestados pudieron tener dudas a la hora de contestar.
- C4 - Los datos de aprendizaje y de análisis deben proceder de fuentes confiables: el ítem está redactado de forma general y no específica si la empresa cuenta con datos procedentes de fuentes confiables.
- CF3 - Los sistemas actuales de la empresa son compatibles con ML: puede verse como que esta variable no explica las condiciones facilitadoras.
- CF5 - La academia proporciona proyectos o iniciativas que me ayudarían a usar ML: puede tomarse como que los encuestados podían tener una interpretación ambigua en cuanto a que no se expresa que la ayuda por parte de la academia sea para la empresa o esta variable no explica las condiciones facilitadoras.
- IS2 - La mayoría de empresas que son importantes para la nuestra han adoptado ML: puede ser que haya un desconocimiento en la adopción de ML en las otras empresas, sin embargo, su valor está muy cerca al límite.
- IS3 - La mayoría de nuestros competidores han adoptado ML: igual que en el anterior ítem, puede ser que haya un desconocimiento en la adopción de ML en las otras empresas.

Por lo anterior, se decide descartar las variables C1, C4, CF3, CF5 e IS3 y calcular de nuevo los valores de fiabilidad individual y la validez convergente. En primer lugar, en esta ocasión todas las variables cuentan con una fiabilidad individual aceptable ( $> 0,7$ ) como se puede observar en la Tabla 5-3. En cuanto a la validez convergente, se observa en la Tabla 5-4 que los constructos siguen cumpliendo con los tres indicadores, menos C que su valor de alfa de Cronbach no supera el umbral, empero, es cercano y los valores de los dos indicadores restantes si los cumple. Por esta razón se puede continuar con la validez discriminante.

**Tabla 5-3.** Cargas de las variables de los constructos ajustados.

<b>C</b>	C2	C3			
	0,97	0,70			
<b>CF</b>	CF1	CF2	CF4	CF6	CF7
	0,78	0,91	0,78	0,86	0,9
<b>IS</b>	IS1	IS2	IS4		
	0,75	0,70	0,91		

**Tabla 5-4.** Validez convergente con los constructos ajustados.

	Alfa de Cronbach	Fiabilidad Compuesta	AVE
AD	0,89	0,95	0,90
C	0,66	0,83	0,71
CF	0,90	0,93	0,72
FU	0,92	0,94	0,76
GD	0,95	0,96	0,79
IS	0,74	0,83	0,63
IU	0,92	0,95	0,86
PV	0,81	0,89	0,72
U	0,86	0,90	0,65
USO	0,95	0,97	0,90

Posteriormente, se analiza las cargas cruzadas de los indicadores y del criterio de Fornell-Larcker para corroborar la validez discriminante. En el Anexo F se puede observar que todos los constructos presentan cargas mayores en los indicadores asociados a su constructo que en otros constructos. En cuanto al criterio de Fornell-Larcker (Tabla 5-5), se visualiza que la raíz cuadrada del AVE de cada constructo es mayor que la correlación más alta con otro constructo.

**Tabla 5-5.** Criterio Fornell-Larcker de las variables latentes.

	AD	CF	C	FU	GD	IS	IU	PV	USO	U
AD	<b>0,95</b>									
CF	0,15	<b>0,85</b>								
C	-0,12	0,20	<b>0,84</b>							
FU	0,46	0,57	0,17	<b>0,87</b>						
GD	0,16	0,53	0,32	0,34	<b>0,89</b>					
IS	0,31	0,30	0,07	0,30	0,21	<b>0,79</b>				
IU	0,44	0,56	0,29	0,64	0,50	0,33	<b>0,92</b>			
PV	0,22	0,42	0,06	0,41	0,27	0,28	0,55	<b>0,85</b>		
USO	0,31	0,73	0,13	0,59	0,44	0,34	0,57	0,43	<b>0,95</b>	
U	0,30	0,32	0,17	0,41	0,24	0,24	0,59	0,64	0,35	<b>0,81</b>

### 5.3. Validación Modelo Estructural

Una vez validado el modelo de medida, se procede a la validación del modelo estructural. Para esto se realiza el análisis Bootstrapping, utilizando también el software SmartPLS con parámetros por defecto, con el fin de conocer cuáles constructos explican la intención de usar y el uso actual de ML. Por ello se analizan los coeficientes path  $\beta$ , T-Statistics y P-Value (Tabla 5-6). En primer lugar, tomando el  $\beta$ , se percibe que la influencia social no supera el valor absoluto de 0,1, por lo que se puede rechazar por el momento la hipótesis H6.

**Tabla 5-6.** Resultados Bootstrapping.

Hipótesis	Coefficiente Path ( $\beta$ )	T Statistics	P Values
AD -> IU (H1)	0,178	2,046 *	0,041 *
CF -> IU (H2)	0,595	6,943 ***	0,000 ***
C -> IU (H3)	0,139	1,552	0,122
FU -> IU (H4)	0,285	2,561 *	0,011 *
GD -> USO (H5)	0,219	2,025 *	0,043 *
IS -> IU (H6)	0,035	0,433	0,665
IU -> USO (H7)	0,237	2,597 **	0,010 **
PV -> IU (H8)	0,181	1,648	0,100
U -> IU (H9)	0,219	2,314 *	0,021 *

Por lo que concierne a los valores de T-Statistics sólo la hipótesis H2 supera el valor crítico ( $t > 3,29$ ) para un nivel de significancia de 0,1%, la hipótesis H7 supera el valor crítico ( $t > 2,58$ ) para un nivel de significancia de 1%; las hipótesis H1, H4, H5 y H9 superan el valor crítico ( $t > 1,96$ ) para un nivel de significancia de 5%, se identifica que las hipótesis H3, H6 y H8 se pueden rechazar con este nivel de significancia.

En consideración a los valores p-value coinciden en el rechazar las hipótesis H3, H6 y H8, para un nivel de significancia de 0,05. Por lo que se puede concluir que los constructos confiabilidad e integridad, influencia social y precio/valor no explican la intención de usar ML en Colombia. En la Figura 5-2 se ilustra el modelo de investigación con los valores de p-value.

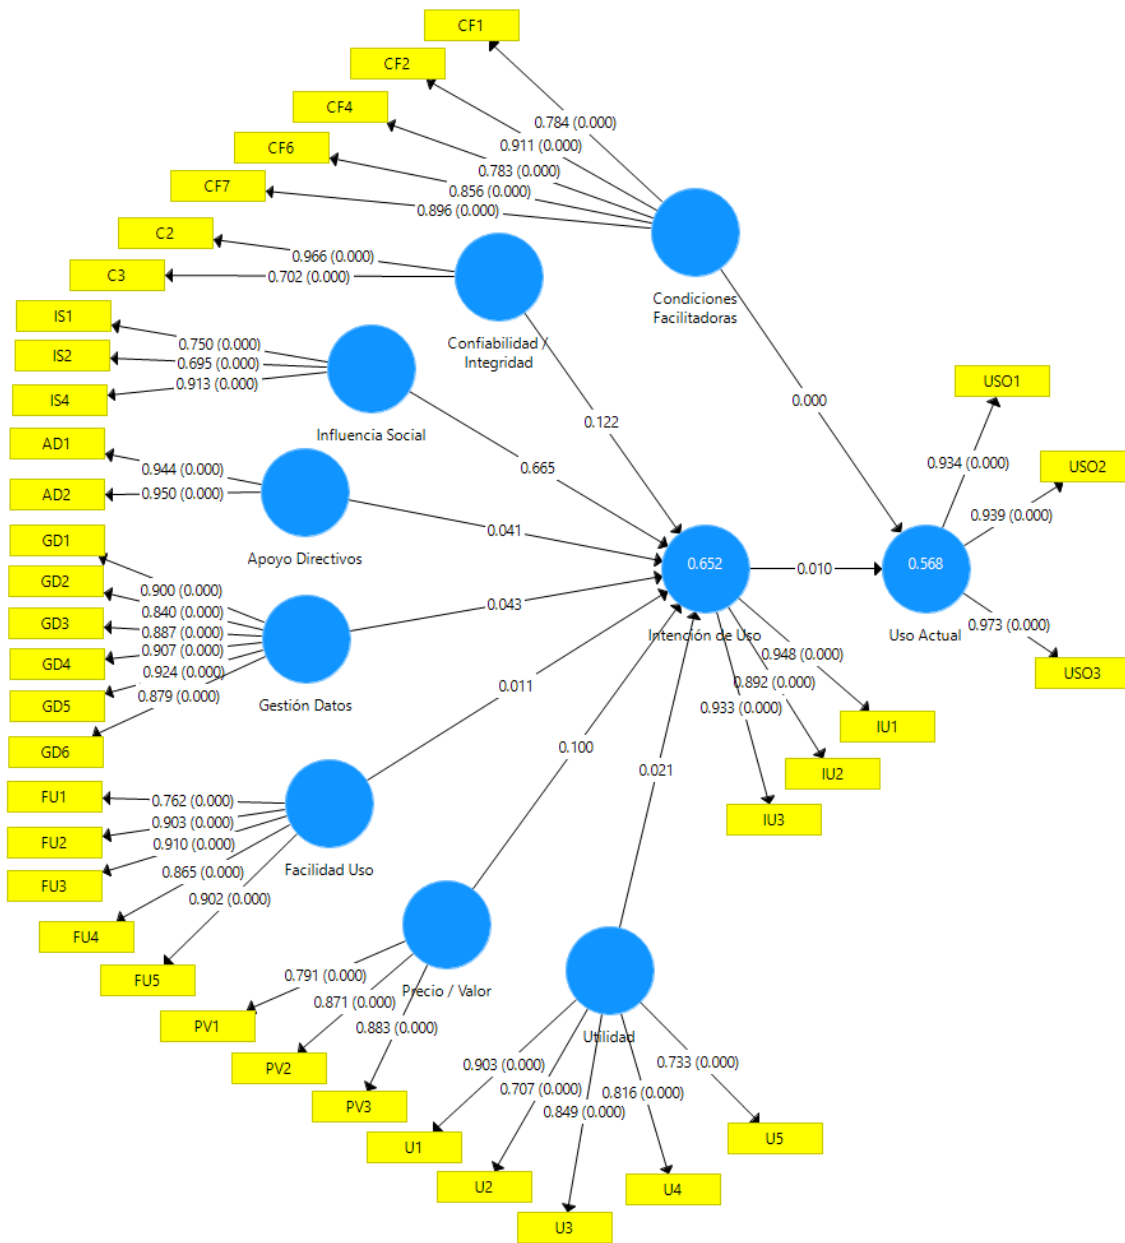


Figura 5-2. Modelo Estructural. Resultante de SmartPLS-3.

Al observar los valores obtenidos de  $f^2$  (Tabla 5-7), se infiere que sólo las condiciones facilitadoras poseen un tamaño de efecto grande ( $f^2 > 0,35$ ), el resto de constructos poseen un tamaño de efecto pequeño, con excepción de la influencia social que no supera el umbral de 0,02, esto reafirma lo encontrado con el coeficiente path ( $\beta$ ).

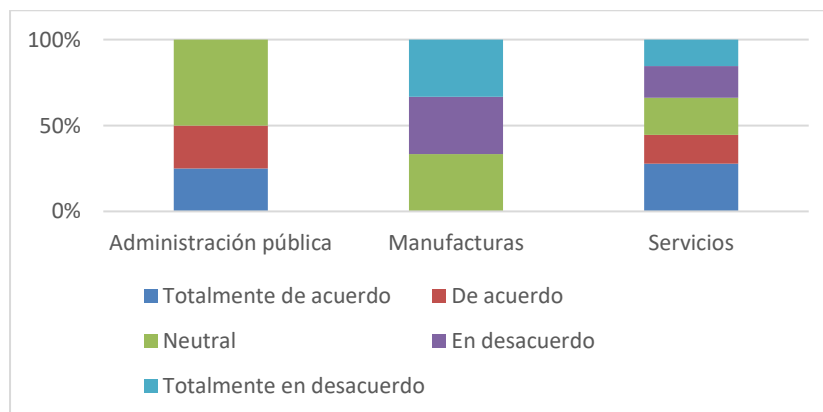
**Tabla 5-7.** Tamaño del efecto ( $f^2$ ).

	IU ( $f^2$ )	USO ( $f^2$ )	Tamaño
<b>AD</b>	0,063		Pequeño
<b>CF</b>		0,568	Grande
<b>C</b>	0,045		Pequeño
<b>FU</b>	0,144		Pequeño
<b>GD</b>	0,108		Pequeño
<b>IS</b>	0,003		N/A
<b>IU</b>		0,090	Pequeño
<b>PV</b>	0,051		Pequeño
<b>U</b>	0,075		Pequeño

En cuanto al coeficiente de determinación  $R^2$  para intención de uso y uso actual, se obtiene un valor de 0,652 y 0,568 respectivamente, lo que indica que la intención de usar ML por empresas colombianas se explica en un 65%, y el uso actual de ML por empresas colombianas se explica en un 57%, superando en ambos casos el criterio de aceptación moderado (> 50%). De igual forma el valor  $Q^2$  es de 0,501 para la intención de uso y 0,498 para el uso actual, valores superiores a 0,35 para ambas variables dependientes que indican un poder altamente predictivo para el modelo estructural completo.

#### 5.4. Intención de Uso y Uso Actual de las Empresas Colombianas Encuestadas

Un total de 42 empresas de 73 encuestadas (58%) expresan un desacuerdo o neutralidad en la generación actual de proyectos con ML. Dentro del sector de administración pública y de servicios menos del 50 % están de acuerdo o totalmente de acuerdo con que generan proyectos con ML. Por el contrario, aproximadamente el 70% de las empresas de manufactura indican que están en desacuerdo o en total desacuerdo con la generación actual de proyectos con ML. En la Figura 5-3 se encuentra el resumen del uso actual por sector económico.



**Figura 5-3.** Uso actual de ML por sector económico. Elaboración propia.

En compensación, en la Figura 5-4 se observa la favorabilidad de 76% en la intención de usar ML por parte de las 42 empresas, que actualmente expresan estar en neutralidad o en desacuerdo con la generación actual de proyectos con ML.



**Figura 5-4.** Intención de usar ML por empresas que actualmente no expresan estar de acuerdo con la generación actual de proyectos con ML. Elaboración propia.

## 6. Conclusiones y Recomendaciones

En este último capítulo se presenta un resumen de los resultados enmarcados en la pregunta y los objetivos de la investigación, cuyo objetivo general “determinar factores que influyen en la adopción de *machine learning* en empresas colombianas” se consigue usando un enfoque multimetodológico, generando una base cualitativa (revisión sistemática de literatura e inferencia de expertos por medio del método Delphi), la cual es validada mediante un método cuantitativo (validación del modelo de adopción a través de PLS-SEM). Del mismo modo, se realiza una reflexión por medio de una discusión de estos resultados, exponiendo limitaciones y recomendaciones para futuras investigaciones.

### 6.1. Resultados de la Investigación

Dando respuesta a los objetivos específicos de la investigación, en los capítulos anteriores se han expuesto los resultados salientes utilizando cada una de las metodologías usadas. A continuación se realiza un resumen puntual de estos resultados asociados a cada uno de los objetivos.

#### 6.1.1 Hallazgos a partir de la RSL más lo inferido de los expertos por medio del método Delphi

Por medio de la revisión sistemática de literatura se encontraron tres artículos que expresan haber usado modelos de adopción para estudiar una aplicación de *machine learning*. En un primer artículo (Kessler & Martin, 2017) se utiliza UTAUT ampliado para estudiar la aceptación de *voicebot*; en un segundo artículo (Kanak & Sogukpinar, 2017) se implementa TAM para estudiar la aceptación de un sistema de autenticación biométrico. Estos dos artículos estudian la aceptación a modo personal, por lo que a pesar que son aplicados a ML no se puede aseverar que funcionen de la misma forma en organizaciones. Por otro lado, el tercer artículo (Rana et al., 2014) desarrolla un *framework* basado también

en TAM aplicado a dos empresas suecas, sin embargo, la validación de este modelo fue por medio de encuestas realizadas a los manager y el equipo que adoptó la tecnología.

Adicionalmente, a través de los quince artículos, incluidos los anteriormente descritos, se encontraron 46 posibles factores que influyen la adopción de *machine learning*. Si bien hay varios artículos que no hacen alusión a esta tecnología en específico si lo hacen a su término padre, inteligencia artificial. Estos factores después de clasificarse se generaron un total de once factores que pueden ser aplicados en un entorno organizacional: “autonomía”, “condiciones facilitadoras”, “confiabilidad e Integridad”, “eficiencia”, “facilidad de uso”, “gestión de datos”, “influencia social”, necesidad e importancia”, “precio / valor”, “riesgo percibido / fiabilidad”, “utilidad”.

En cuanto al método Delphi, se infirieron por medio de los expertos, en una primera instancia 31 posibles factores que influyen la adopción de *machine learning*, los cuales se agruparon en 16 y por medio de las iteraciones se llegaron a un consenso de trece factores: “beneficios percibidos”, “posible ventaja competitiva”, “conocimientos de la materia”, “disponibilidad de datos”, “objetivo muy bien definido (¿Para qué se va a usar específicamente?)”, “utilidad percibida”, “costos de adopción”, “apoyo de los directivos”, “calidad de los datos”, “constante evolución de las herramientas y/o algoritmos”, “facilidad de modelamiento del objetivo”, “integridad de las herramientas TIC”, “influencia social”.

Estos factores resultantes, se asociaron a los encontrados en la literatura, pudiéndose agrupar once de los factores inferidos por los expertos, quedando sin asociación “apoyo a directivos”. Esta agrupación sirve como base para la construcción del modelo de adopción de *machine learning*.

### **6.1.2 Hallazgos a partir de la validación del modelo de adopción planteado**

Teniendo en cuenta los factores que fueron inferidos mediante la RSL y que también tuvieron una asociación de lo encontrado con la ayuda del método Delphi, más “apoyo a directivos”, se construye un modelo de adopción de *machine learning*, tomando como base UTAUT, generando como hipótesis a validar: Las condiciones facilitadoras y la intención de uso se relacionan positivamente con el uso actual de *machine learning* por parte de las empresas colombianas, y, la confiabilidad e integridad, la facilidad de uso, la gestión de datos, la influencia social, el precio / valor, la utilidad y el apoyo de los directivos se



relacionan positivamente con la intención de usar *machine learning* por parte de las empresas colombianas.

Este modelo fue validado por intermedio de un instrumento tipo encuesta aplicada a tomadores de decisiones de empresas colombianas; posteriormente, fue analizado a través de PLS-SEM, generando como resultados, entre muchos, la aceptación de las hipótesis: la facilidad de uso, la gestión de datos, la utilidad y el apoyo de los directivos se relacionan positivamente con la intención de usar *machine learning* por parte de las empresas colombianas, con un 65% de explicación de la intención de uso. También la aceptación de las hipótesis: las condiciones facilitadoras y la intención de uso se relacionan positivamente con el uso actual de *machine learning* por parte de las empresas colombianas, con un 57% de explicación del uso actual.

## 6.2. Discusión de Resultados

A lo largo de la revisión de literatura se concibe que tanto *machine learning* como inteligencia artificial, son términos que han tenido un gran foco de estudio. Se encontró que han sido muy utilizados en diversas ramas de la ciencia, sin embargo, se percibe que aún se encuentra más en la academia, y a pesar de los avances recientes, este enfoque rara vez se emplea en los sistemas de apoyo a la decisión, infiriendo que el valor comercial de las máquinas de aprendizaje en aplicaciones prácticas generalmente no se conoce (Kraus & Feuerriegel, 2017).

No obstante, no se pueden negar los múltiples beneficios que se le atribuyen, por esto es una necesidad tener conocimiento de qué puede influir en la adopción de esta tecnología. Es por eso que los factores encontrados mediante la literatura nos dan un buen acercamiento a entender este fenómeno de adopción, empero, como se puede observar más adelante, en un entorno organizacional y en especial en el colombiano, no todos estos factores son aplicables.

El método Delphi presenta un proceso de inferencia de datos a través de expertos muy apropiado para generación de conocimiento colectivo y a distancia. La deserción de los candidatos causó una gran preocupación debido a que se finalizó el estudio con ocho expertos, sin embargo, y tal como lo indican algunos autores (Cabrerero & Llorente, 2013; Landeta, 2002), el mínimo número de expertos debería ser siete para que la información se considere válida. Además, representaron áreas pertinentes para el estudio: dos

académicos orientados a gerencia de TI, cuatro académicos orientados a inteligencia artificial y dos profesionales gerentes, líderes, analistas y/o desarrolladores de TI.

Se observa que de los factores resultantes de la asociación entre lo inferido de la literatura y lo concertado por los expertos, la mayoría de aquellos que fueron mencionados por ambas partes son la base del UTAUT (condiciones facilitadoras, influencia social y precio / valor) y del TAM (facilidad de uso y utilidad). Esto reafirma que son modelos que permiten el estudio de adopción de una amplia variedad de tecnologías, aunque cabe recalcar que, para *machine learning* es necesario incorporar factores adicionales al modelo para obtener una mejor explicación del fenómeno de adopción. La confiabilidad e integridad, la gestión de datos y el apoyo de los directivos son factores importantes a considerar para determinar la intención y uso de *machine learning*.

A pesar que el número de la muestra obtenida para la validación del modelo no superó el umbral sugerido por Marcoulides y Saunders (2006, Martínez & Fierro, 2018), y que esto podría afectar las cargas y/o la fiabilidad de cada constructo, después de los análisis estadísticos dan poder altamente predictivo para el modelo estructural y un porcentaje explicativo del 65% de la intención de uso del *machine learning* en la empresas colombianas.

En conclusión, se da validez a que los factores organizacionales (condiciones facilitadoras, facilidad de uso, utilidad y apoyo a los directivos), y el factor técnico (gestión de datos), son influyentes en la adopción de *machine learning* en un entorno empresarial colombiano. Cabe destacar que la gestión de datos y el apoyo de los directivos, son adiciones importantes a considerar para la adopción de esta tecnología. Adicionalmente, el apoyo de los directivos es resultante únicamente de lo indicado por los expertos, por lo que corrobora la teoría que es necesario fusionar varios puntos de vista del mundo para complementar la visión de un objeto de estudio, soportando la multimetodología utilizada en esta investigación.

En cuanto a la validez de la hipótesis la cual expresa que la gestión de datos está relacionada positivamente a la intención de uso de *machine learning*, se entiende debido a que es un tecnología sumamente dependiente de los datos. De igual forma, variables como experiencia previa, poseer tecnología para la gestión de datos y la facilidad de

modelamiento que nos son propias de los modelos base, resultaron ser explicativas para sus respectivos constructos, siendo factores propios de esta tecnología.

Por otro lado, se contempla que el constructo cuyos valores expresan mayor rechazo a la hipótesis planteada es la influencia social, también está soportado en la cuantificación del grado de influencia que dieron los expertos que fue de las más bajas. Esto podría indicar que las empresas no sienten que deberían utilizar *machine learning* solamente porque instituciones que son importantes para ellas lo utilizan. Este es un hallazgo significativo que diferencia la adopción de tecnologías a nivel empresarial del nivel individual. La literatura reporta que la influencia social generalmente resulta ser un factor que predice la intención de uso de tecnología a nivel individual (Fernández Robin, McCoy, Yáñez Sandivari, & Yáñez Martínez, 2014; Kessler & Martin, 2017).

El constructo de precio/valor también se rechazó después del análisis estadístico multivariante, sin embargo, los valores aceptarían la hipótesis si se tomaran umbrales de tipo exploratorio, por lo que en este caso, con una muestra mayor podría o reafirmar o desestimar los valores para este constructo de esta investigación. Por último, la confiabilidad e integridad igualmente fue rechazada, en este caso, la fiabilidad interna de este constructo puede afectar el resultado obtenido, y esto se debe a una interpretación ambigua o formulación inadecuada de los identificadores del mismo.

Si bien esta investigación, proporciona un modelo de adopción de *machine learning*, cabe resaltar que fue validado en el entorno colombiano, por lo que se da pie a realizar validaciones en otros países, inclusive recolectar una muestra mayor para Colombia. Futuros estudios podrían centrarse en validar el modelo en tecnologías hermanas a *machine learning* como *deep learning* y/u otras herramientas analíticas predictivas.



## A. Anexo: Matriz para selección de expertos por medio del biograma del experto.

Tabla A-1. Matriz para selección de expertos por medio del biograma del experto.

Tipo de Experto	Categoría	Puntaje Máx.	Ítems	Puntos		Valor por unidad	Equivalente Excelente
				SI	NO		
Académicos orientados a gerencia de TI	Experiencia académica (Docente, tutor, conferencista) relacionada con	20	Adopción de Tecnología	20	0		
		25	Adopción de Nuevas Tecnologías	25	0		
		15	Machine Learning	15	0		
	# Publicaciones relacionadas con	10	Adopción de Tecnología	NA	NA	2	5 publicaciones
		20	Adopción de Nuevas Tecnologías	NA	NA	4	5 publicaciones
		5	Machine Learning	NA	NA	1	5 publicaciones
	# Proyectos relacionados con	5	Adopción de Tecnología	NA	NA	1	5 proyectos
		5	Adopción de Nuevas Tecnologías	NA	NA	1	5 proyectos
		5	Machine Learning	NA	NA	1	5 proyectos
Académicos orientados a Inteligencia Artificial	Experiencia académica (Docente, tutor, conferencista) relacionada con	10	Adopción de Tecnología	10	0		
		15	Inteligencia Artificial	15	0		
		25	Machine Learning	25	0		
	# Publicaciones relacionadas con	5	Adopción de Tecnología	NA	NA	1	5 publicaciones
		10	Inteligencia Artificial	NA	NA	2	5 publicaciones
		15	Machine Learning	NA	NA	3	5 publicaciones
	# Proyectos relacionados con	5	Adopción de Tecnología	NA	NA	1	5 proyectos
		10	Inteligencia Artificial	NA	NA	2	5 proyectos
		15	Machine Learning	NA	NA	3	5 proyectos
Profesionales gerentes, líderes, analistas y/o	Experiencia en gerencia, análisis, desarrollo y/o implementación relacionada con	5	Adopción de TI	5	0		
		5	Nuevas Tecnologías	5	0		
		10	Inteligencia Artificial	10	0		

desarrolladores de TI		20	Machine Learning	20	0		
	Años de experiencia relacionados con	5	Adopción de Nuevas Tecnologías	NA	NA	1	5 años
		10	Adopción de Inteligencia Artificial	NA	NA	3,33	3 años
		15	Adopción de Machine Learning	NA	NA	5	3 años
	# proyectos relacionados con	5	Adopción de Nuevas Tecnologías	NA	NA	1	5 años
		10	Adopción de Inteligencia Artificial	NA	NA	3,33	3 años
		15	Adopción de Machine Learning	NA	NA	5	3 años

## B. Anexo: Resultados biograma del experto.

Teniendo en cuenta la matriz del biograma experto se califica cada uno de los expertos.

En las tablas **Tabla B-1**, **Tabla B-2** y **Tabla B-3** se observan las calificaciones respectivas.

Con aras de resumir la tabla se utiliza una serie de convenciones:

<b>AT: Adopción de Tecnología</b>	<b>NT: Nuevas Tecnologías</b>
<b>AIA: Adopción de Inteligencia Artificial</b>	<b>Ca: Canada</b>
<b>AML: Adopción de Machine Learning</b>	<b>Co: Colombia</b>
<b>ANT: Adopción de Nuevas Tecnologías</b>	<b>Ch: Chile</b>
<b>IA: Inteligencia Artificial</b>	<b>Es: España</b>
<b>ML: Machine Learning</b>	<b>Pe: Perú</b>

- **Académicos orientados a gerencia de TI**

**Tabla B-1.** Resultados biograma de los expertos académicos orientados a gerencia de TI.

N°	Título	Cargo	Experiencia académica (Docente, tutor, conferencista) relacionada con			# Publicaciones relacionadas con			# Proyectos relacionados con			TOTAL
			AT	ANT	ML	AT	ANT	ML	AT	ANT	MLA	
Experto 1 (Es)	PhD Ciencias de la Computación	Docente e Investigador	20	25	0	8	8	0	5	4	0	<b>70</b>
Experta 2 (Co)	PhD en economía y gestión de la innovación y política TI	Docente e Investigadora	20	25	0	10	16	0	3	0	0	<b>74</b>
Experto 3 (Co)	Msc en ingeniería industrial	Docente e Investigador	20	25	0	10	8	0	4	3	0	<b>70</b>
Experta 4 (Co)	PhD en Ciencias Administrativas	Docente e Investigadora	20	25	0	10	16	0	4	2	0	<b>77</b>
Experto 5 (Ch)	PhD en Economía y Administración de Empresas	Docente e Investigador	20	25	0	10	16	0	2	0	0	<b>73</b>

Experto 6 (Ch)	Doctor en Sistemas de Información en la Empresa	Docente e Investigador	20	25	0	10	16	0	0	0	0	71
Experto 7 (Ch)	PhD en Sistemas de Información	Docente e Investigador	20	25	0	10	20	0	0	0	0	75
Experta 8 (Co)	Doctora en Ingeniería, Industria y Organizaciones	Docente e Investigadora	20	25	0	6	4	0	0	0	0	55
Experto 9 (Es)	Doctor en ciencias físicas	Docente e Investigador	20	25	0	0	4	0	5	4	0	58

- **Académicos orientados a inteligencia artificial**

**Tabla B-2.** Resultados biograma de los expertos académicos orientados a inteligencia artificial.

N°	Título	Cargo	Experiencia académica (Docente, tutor, conferencista) relacionada con			# Publicaciones relacionadas con			# Proyectos relacionados con			TOTAL
			AT	IA	ML	AT	IA	ML	AT	IA	MLA	
Experto 10 (Es)	Doctor en ciencias y tecnologías industriales	Docente e Investigador	0	15	25	0	10	15	5	10	15	95
Experto 11 (Es)	Doctor en ciencias y tecnologías industriales	Docente e Investigador	0	15	25	0	10	15	5	10	6	86
Experta 12 (Es)	Doctora en ciencias y tecnologías industriales	Docente e Investigadora	0	15	25	0	10	15	0	4	3	72
Experto 13 (Co)	PhD Ciencias de la Computación	Docente e Investigador	0	15	25	0	10	15	5	10	12	92
Experto 14 (Es)	Doctor en ciencias y tecnologías industriales	Docente e Investigador	0	15	25	0	10	15	5	10	6	86
Experto 15 (Es)	Doctor en ciencias y tecnologías industriales	Docente e Investigador	0	15	25	0	10	15	5	10	9	89



Experto 16 (Co)	PhD en Ingeniería de Sistemas y Computación	Docente e Investigador	0	15	25	0	10	15	5	10	6	86
Experto 17 (Ch)	PhD en Ingeniería Informática y de Telecomunicación	Docente e Investigador	0	15	25	0	10	15	3	2	0	70
Experto 18 (Ch)	PhD en Ciencias de la Computación	Docente e Investigador	0	15	25	0	10	15	1	2	3	71
Experto 19 (Co)	Doctor en Ingeniería	Docente e Investigador	0	15	25	0	10	15	1	2	3	71
Experto 20 (Co)	PhD en Matemáticas con énfasis en Ciencias de la Computación	Docente e Investigador	0	15	25	0	10	15	5	6	0	76
Experto 21 (Co)	PhD en Matemáticas con énfasis en Ciencias de la Computación	Docente e Investigador	0	15	25	0	10	15	3	2	0	70
Experto 22 (Co)	Doctor de Filosofía en Ciencias Matemáticas	Docente e Investigador	0	15	25	0	10	15	5	10	15	95
Experta 23 (Co)	Doctora en Ciencias de la Computación	Docente e Investigadora	10	15	25	1	10	15	5	10	9	100
Experto 24 (Co)	PhD en Ingeniería	Docente e Investigador	0	15	25	0	10	15	5	10	12	92
Experto 25 (Ch)	Doctor en Automática, procesamiento de señales e Ing. Informática	Docente e Investigador	0	15	25	5	10	12	5	10	12	94
Experto 26 (Co)	Msc en ingeniería industrial	Docente e Investigadora	0	15	25	0	10	0	1	2	0	53
Experto 27 (Ch)		Docente e Investigadora	0	15	25	0	10	12	0	0	0	62

- **Profesionales gerentes, líderes, analistas y/o desarrolladores de TI**

**Tabla B-3.** Resultados biograma de los expertos profesionales gerentes, líderes, analistas y/o desarrolladores de TI.

N°	Título	Cargo	Experiencia en gerencia, análisis, desarrollo y/o implementación relacionada con				Años de experiencia relacionados con			# proyectos relacionados con			TOTAL
			AT	NT	IA	ML	AT	AIA	AML	AT	AIA	AML	
Experto 28 (Ca)	Msc Ciencias Avanzadas de la Computación y Gerencia TI	Ingeniera de Software	5	5	10	20	5	6,7	10	5	3,4	5	<b>75,1</b>
Experto 29 (Pe)	Magíster en Ingeniería - Ingeniería de Sistemas y Computación	Director de Ingeniería y Analítica	5	5	10	20	5	10	15	5	6,7	0	<b>81,7</b>
Experto 30 (Co)	Ingeniera de Sistemas	Desarrolladora de Software	5	5	10	20	5	6,7	10	5	6,7	10	<b>83,4</b>
Experto 31 (Co)	Master en Ingeniería de Información	Arquitecto de Soluciones	5	5	10	20	5	10	5	5	10	5	<b>80</b>

## C. Anexo: Cuestionario para determinar coeficiente experto.

El siguiente cuestionario es utilizado para determinar el coeficiente de competencia experta:

- Considerando que las tecnologías como Internet de las cosas, robótica, inteligencia artificial, *machine learning*, cadena de bloques (*blockchain*) se catalogan como la tercera ola de la digitalización en innovación tecnológica (R. Katz & Callorda, 2017); teniendo en cuenta su experiencia profesional y académica en una escala del 0 al 10 ¿Cuál es el grado de conocimiento que posee con respecto a adopción de tecnologías de la tercera ola de la digitalización? Representando "0" como conocimiento nulo mientras que "10" pleno conocimiento.
- En una escala de bajo, medio y alto califique cual es el grado de influencia de cada factor en su conocimiento con respecto a adopción de tecnologías de la tercera ola de la digitalización.

	Bajo	Medio	Alto
Experiencia obtenida a través de su actividad y práctica.			
Conocimiento sobre el estado de la cuestión a nivel nacional e internacional.			
Intuición sobre el tema abordado y conocimiento sobre tecnología.			
Estudio de trabajos y publicaciones sobre el tema.			

## D. Anexo: Cuestionario para validación modelo.

- **Información Demográfica**

1. Sector económico de su empresa.
2. Años con los que cuenta la empresa.
3. ¿Cuántas personas aproximadamente trabajan en la empresa?
4. Cargo que posee dentro de la empresa.

En la siguiente sección indique su grado de acuerdo según estas alternativas:

- |                                   |                          |
|-----------------------------------|--------------------------|
| 1. Totalmente en desacuerdo       | 4. De acuerdo            |
| 2. En desacuerdo                  | 5. Totalmente de acuerdo |
| 3. Ni de acuerdo ni en desacuerdo |                          |

Instrucciones: Encierre sólo un número por fila.	1	2	3	4	5
<b>TÉCNICOS</b>					
<b>CONFIABILIDAD / INTEGRIDAD (C)</b>					
C1. La información proporcionada por los algoritmos de ML debe ser consistente.	1	2	3	4	5
C2. La información generada por los algoritmos de ML debe ser significativa.	1	2	3	4	5
C3. La información proporcionada por los algoritmos de ML debe generar los resultados esperados.	1	2	3	4	5
C4. Los datos de aprendizaje y de análisis deben proceder de fuentes confiables.	1	2	3	4	5
<b>GESTION DE DATOS (GD)</b>					
GD1. Existen políticas de seguridad de la data recolectada o generada por los diferentes sistemas.	1	2	3	4	5
GD2. Existen políticas de privacidad de la información generada por los algoritmos de ML.	1	2	3	4	5
GD3. Existen protocolos de integración de datos de diferentes fuentes que se puedan relacionar.	1	2	3	4	5
GD4. Nuestra empresa cuenta con almacenamiento suficiente de la data tanto para aprendizaje como para análisis.	1	2	3	4	5
GD5. Nuestra empresa posee las tecnologías para el procesamiento de la data de forma eficiente.	1	2	3	4	5

GD6. ¿Cómo clasifica el nivel de digitalización de la empresa? Donde 1 es muy bajo y 5 Muy alto.

<b>EXTERNOS</b>					
<b>INFLUENCIA SOCIAL (IS)</b>					
IS1. La mayoría de las empresas que influyen en nuestras decisiones creen que deberíamos adoptar ML.	1	2	3	4	5
IS2. La mayoría de empresas que son importantes para la nuestra han adoptado ML.	1	2	3	4	5
IS3. La mayoría de nuestros competidores han adoptado ML.	1	2	3	4	5
IS4. En el entorno de la empresa se considera que adoptar ML genera mayor prestigio.	1	2	3	4	5
<b>ORGANIZACIONALES</b>					
<b>APOYO DE LOS DIRECTIVOS (AD)</b>					
AD1. Los directivos muestran interés en la adopción de tecnologías como ML.	1	2	3	4	5
AD2. Desde la mesa directiva se piensa en destinar presupuesto para adoptar tecnologías como ML.	1	2	3	4	5
<b>CONDICIONES FACILITADORAS (CF)</b>					
CF1. Nuestra empresa tiene los recursos para usar ML	1	2	3	4	5
CF2. Nuestra empresa posee el conocimiento necesario para usar ML	1	2	3	4	5
CF3. Los sistemas actuales de la empresa son compatibles con ML.	1	2	3	4	5
CF4. El apoyo de la academia o profesionales expertos facilitaría la adopción de ML.	1	2	3	4	5
CF5. Las tecnologías para la gestión de datos de nuestra empresa facilitan el uso de ML.	1	2	3	4	5
CF6. La academia proporciona proyectos o iniciativas que me ayudarían a usar ML.	1	2	3	4	5
CF7. Nuestra empresa tiene disponible personal si hay problemas al usar ML.	1	2	3	4	5
CF8. Tener experiencia previa con ML facilita el uso de esta tecnología.	1	2	3	4	5
<b>FACILIDAD DE USO (FU)</b>					
FU1. El proceso de modelamiento de los algoritmos de ML sería claro y comprensible para personas de nuestra empresa.	1	2	3	4	5
FU2. Sería fácil para nuestra empresa familiarizarse con ML.	1	2	3	4	5
FU3. Para nuestra empresa sería fácil usar ML.	1	2	3	4	5
FU4. Considero que aprender ML sería fácil para personal de nuestra empresa.	1	2	3	4	5

FU5. Interpretar los resultados obtenidos de ML sería fácil para nuestra empresa.					
<b>PRECIO / VALOR (PV)</b>					
PV1. ML tiene un precio razonable.	1	2	3	4	5
PV2. ML ofrece un valor agregado para nuestra empresa.	1	2	3	4	5
PV3. ML posee una buena relación costo/beneficio	1	2	3	4	5
<b>UTILIDAD (U)</b>					
U1. Usar ML será útil para la empresa.	1	2	3	4	5
U2. Usar ML generará una ventaja competitiva frente a mis competidores.	1	2	3	4	5
U3. Usar ML proporcionará información útil para la toma de decisiones en la empresa.	1	2	3	4	5
U4. Usar ML facilitaría algunos procesos de la empresa.	1	2	3	4	5
U5. Usar ML podría mejorar la productividad de la compañía.	1	2	3	4	5
<b>INTENCIÓN DE USO (IU)</b>					
IU1. Nuestra empresa tiene la intención de usar ML en el futuro	1	2	3	4	5
IU2. Siempre que se pueda, la empresa intentará usar ML.	1	2	3	4	5
IU3. Nuestra empresa tiene planes de usar ML próximamente.	1	2	3	4	5

En dado caso que la empresa tenga planes de usar ML ¿Qué tan próximos se comenzarán a desarrollar esos proyectos?

- De 1 a 3 meses
- De 3 a 6 meses
- De 6 meses a 1 año
- De 1 año a 2 años
- De 3 años en adelante

¿Cuál es la duración aproximada estimada de estos proyectos?

- De 1 a 3 meses
- De 3 a 6 meses
- De 6 meses a 1 año
- De 1 año a 2 años
- De 3 años en adelante

<b>USO</b>					
USO1. Nuestra empresa genera proyectos con ML frecuentemente.	1	2	3	4	5
USO2. Nuestra empresa pasa mucho tiempo tratando de generar proyectos con ML.	1	2	3	4	5
USO3. Nuestra empresa se involucra mucho en proyectos con ML.	1	2	3	4	5

## E. Anexo: Factores que pueden influir en la adopción de *machine learning* según la literatura.

**Tabla E-1.** Factores encontrados en la literatura que pueden influir en la adopción de *machine learning*.

Artículo(s)	Temática estudiada	Contexto	Modelo Teórico Relacionado	Factores asociados	Descripción
(1) (Berge, 2018)	Chatbot	Uso personal	MOT	Riesgo Percibido / Fiabilidad (1)	Grado de incertidumbre sobre si se lograrán resultados de decisiones potencialmente significativos o decepcionantes.
				Confiabilidad / Integridad (2)	Creencia que la tecnología específica funcionará de manera consistente y manera adecuada, es decir, de manera confiable que proporcione al usuario respuestas esperadas y significativas.
(2) (Kessler & Martin, 2017)	Voicebot	Uso personal	UTAUT Ampliado	Condiciones facilitadoras (3)	Se refiere a las percepciones de los consumidores sobre los recursos y el apoyo disponibles para realizar un comportamiento.
				Expectativa de desempeño (4)	Grado en que el uso de una tecnología proporcionará beneficios para los consumidores al realizar ciertas actividades.
				Expectativa de esfuerzo (5)	Grado de facilidad asociado con el uso de tecnología por parte de los consumidores.
				Hábito (6)	Medida en que las personas tienden a realizar comportamientos automáticamente debido al aprendizaje.
				Influencia social (7)	Medida en que los consumidores perciben que otros creen que deberían usar una tecnología en particular.

				Precio / Valor (8)	Compensación de los consumidores entre los beneficios percibidos de las aplicaciones y el costo monetario por usarlas.
			N/A	Relación con la tecnología (9)	Percepción frente a las máquinas inteligentes y lo que pudiesen hacer.
				Seguridad de la data (10)	Medida de confianza sobre el control y transparencia de la información recopilada.
(3) (Kanak & Sogukpinar, 2017)	Biometric authentication systems	Usuarios de autenticación biométrica	TAM	Facilidad de uso percibida (11)	Grado en que una persona cree que usar una tecnología estaría libre de esfuerzo.
				Utilidad percibida (12)	Probabilidad subjetiva del usuario potencial que el uso de una tecnología facilita los procesos.
			N/A	Confianza (13)	Medida de garantía con los usuarios para que puedan realizar transacciones de forma segura y su información personal se mantenga confidencial.
(4) (R Rana et al., 2014), (5) (R Rana, 2015), (6) (Rakesh Rana et al., 2015)	Machine learning	2 Industrias (Directores)	TAM	Facilidad de uso percibida (14)	Grado en que una persona cree que usar una tecnología estaría libre de esfuerzo.
				Utilidad percibida (15)	Probabilidad subjetiva del usuario potencial que el uso de una tecnología facilita los procesos.
			N/A*	Adopción en otras industrias (16)	Si se adopta una tecnología en diferentes industrias, indica su aplicabilidad en la práctica.
				Barreras percibidas (17)	Barreras como curva de aprendizaje, las partes interesadas en proyectos de software quienes están acostumbrados a los enfoques tradicionales generalmente no confían en los algoritmos para superar las predicciones basadas en expertos, predicciones erróneas.
				Competencia en ML (18)	Organizaciones con enfoques de aprendizaje automático a través de su fuerza de trabajo o colaboraciones con la academia
				Disponibilidad de herramientas (19)	Algunos de los atributos relacionados con este factor son: si las herramientas disponibles son de código abierto o de propietarios, cuánto soporte está disponible y cuánto cuestan.



				Familiaridad con ML (20)	Comprensión de las ventajas y limitaciones de la tecnología.
				Necesidad e importancia (21)	Grado de necesidad e importancia de la información dada en una organización
				Satisfacción con sistemas existentes (22)	Grado de satisfacción de las organizaciones con sus actuales sistemas de medición / análisis.
				Usado por los competidores (23)	La adopción de una técnica / proceso particular por parte de un competidor es una señal fuerte que una técnica dada podría tener beneficios potenciales.
(6) (Rakesh Rana et al., 2015)	Software Defect Prediction	Directores de una industria automotriz	N/A*	Costos (24)	Valor monetario de la adopción.
(7) (Huckvale et al., 2019)	Digital health		N/A*	Autonomía (25)	Capacidad de la tecnología en la automatización de procesos.
				Privacidad (26)	Confidencialidad en los resultados y procesos.
				Seguridad de la data (27)	Confidencialidad de la información de cada usuario.
(8) (Nilsson & Sandin, 2018)	Interoperability in Industry 4.0		N/A*	Interoperabilidad (28)	Capacidad de dos o más sistemas o componentes para intercambiar y usar la información de intercambio en una red heterogénea.
(9) (Narayan, Qazi, & Kannan, 2018)	Frameworks de ML		N/A*	Ejecución interpretada (29)	Algoritmos que no necesitan ser preprocesados.
				Consumo de memoria (30)	Medida de cantidad de memoria requerida para procesar los algoritmos.
(10) (Stead, 2018), (11) (Naylor, 2018)	Clinical Medicine IA Software		N/A*	Experiencia con ML (31)	Conocimiento en la implementación de algoritmos.
				Facilidad de uso (32)	Grado de dificultad en el uso de la tecnología.
				Funcionalidad (33)	Capacidad de la tecnología en hacer lo que debe,
				Necesidad (34)	Carencia de algún proceso o funcionalidad que la nueva tecnología puede suplir.
				Soporte (35)	Grado de ayudas que la herramienta posee.
(12) (Fernandez-			N/A*	Consumo de memoria (36)	Desempeño computacional de calidad, que responda a los tiempos necesarios.

Luque & Imran, 2018)	Humanitarian health computing			Credibilidad de la información (37)	Credibilidad en los resultados generados.
				Marcos que faciliten el intercambio de datos (38)	Integración de datos de distintas fuentes, destacando la necesidad de más trabajo sobre interoperabilidad y políticas para fomentar el intercambio de datos
				Políticas de gestión de datos (39)	Gestión de datos para obtener información de calidad.
(13) (Gao et al., 2018)	Facilitating Usable AI Development		N/A*	Eficiencia (40)	Desempeño óptimo de los algoritmos.
				Fiabilidad (41)	Credibilidad en los resultados generados.
				Interoperabilidad (42)	Generación de resultados fáciles de entender.
				Seguridad de la data (43)	Control de la confidencialidad de la data.
				Usabilidad (44)	Facilidad en el uso.
(14) (Chew, Wong, & Ooi, 2017)	ML Privacy Protection		N/A*	Poseer data training (45)	Gestión de data propicia para entrenar los algoritmos.
(15) (Russu, Demontis, Biggio, Fumera, & Roli, 2016)	Network Evasion Attacks		N/A*	Complejidad de entrenamiento (46)	Dificultad en el aprendizaje propio del algoritmo.

## F. Anexo: Cargas cruzadas de los indicadores y las variables latentes.

Tabla F-1. Cargas cruzadas de los indicadores y las variables latentes Colombia

	AD	C	CF	FU	GD	IS	IU	PV	U	USO
AD1	<b>0,94</b>	-0,10	0,14	0,42	0,15	0,22	0,40	0,24	0,29	0,31
AD2	<b>0,95</b>	-0,14	0,13	0,44	0,15	0,36	0,43	0,17	0,28	0,29
C1	-0,09	<b>0,97</b>	0,20	0,17	0,34	0,06	0,31	0,05	0,14	0,13
C2	-0,18	<b>0,70</b>	0,11	0,10	0,14	0,06	0,11	0,07	0,17	0,06
CF1	0,17	0,17	<b>0,78</b>	0,42	0,36	0,28	0,55	0,40	0,41	0,46
CF2	0,02	0,15	<b>0,91</b>	0,51	0,37	0,22	0,41	0,26	0,15	0,63
CF4	0,13	0,17	<b>0,78</b>	0,43	0,50	0,29	0,41	0,42	0,26	0,52
CF6	0,07	0,19	<b>0,86</b>	0,48	0,46	0,26	0,45	0,28	0,16	0,50
CF7	0,21	0,17	<b>0,90</b>	0,57	0,53	0,26	0,54	0,43	0,37	0,84
FU1	0,37	0,12	0,50	<b>0,76</b>	0,20	0,23	0,39	0,21	0,26	0,60
FU2	0,44	0,17	0,48	<b>0,90</b>	0,31	0,22	0,57	0,31	0,35	0,48
FU3	0,39	0,24	0,60	<b>0,91</b>	0,45	0,31	0,68	0,44	0,41	0,57
FU4	0,45	0,00	0,39	<b>0,87</b>	0,18	0,29	0,45	0,29	0,25	0,39
FU5	0,36	0,17	0,50	<b>0,90</b>	0,28	0,23	0,61	0,47	0,49	0,52
GD1	0,13	0,38	0,42	0,27	<b>0,90</b>	0,09	0,42	0,22	0,16	0,32
GD2	0,12	0,24	0,46	0,23	<b>0,84</b>	0,19	0,38	0,24	0,19	0,38
GD3	0,07	0,33	0,38	0,27	<b>0,89</b>	0,19	0,38	0,23	0,20	0,40
GD4	0,16	0,24	0,40	0,28	<b>0,91</b>	0,22	0,49	0,21	0,21	0,39
GD5	0,15	0,32	0,55	0,39	<b>0,92</b>	0,23	0,54	0,29	0,31	0,44
GD6	0,19	0,19	0,60	0,37	<b>0,88</b>	0,21	0,41	0,26	0,21	0,44
IS1	0,14	0,10	0,20	0,24	0,18	<b>0,75</b>	0,19	0,20	0,21	0,21
IS2	-0,02	0,22	0,21	0,17	0,09	<b>0,70</b>	0,12	0,22	0,11	0,32
IS4	0,41	-0,02	0,29	0,27	0,20	<b>0,91</b>	0,37	0,25	0,22	0,30
IU1	0,42	0,24	0,51	0,59	0,51	0,28	<b>0,95</b>	0,49	0,60	0,52
IU2	0,39	0,30	0,49	0,58	0,42	0,38	<b>0,89</b>	0,54	0,53	0,57
IU3	0,41	0,25	0,54	0,61	0,46	0,26	<b>0,93</b>	0,50	0,50	0,49
PV1	0,15	0,05	0,27	0,28	0,20	0,22	0,40	<b>0,79</b>	0,45	0,33
PV2	0,33	-0,05	0,40	0,47	0,28	0,26	0,52	<b>0,87</b>	0,62	0,36
PV3	0,06	0,16	0,39	0,28	0,20	0,23	0,48	<b>0,88</b>	0,53	0,41
U1	0,32	0,13	0,32	0,40	0,21	0,28	0,64	0,61	<b>0,90</b>	0,30
U2	0,26	0,20	0,19	0,45	0,18	0,26	0,46	0,38	<b>0,71</b>	0,33
U3	0,22	0,08	0,35	0,29	0,25	0,16	0,47	0,58	<b>0,85</b>	0,36
U4	0,16	0,11	0,16	0,17	0,20	0,12	0,36	0,45	<b>0,82</b>	0,18
U5	0,19	0,17	0,23	0,31	0,12	0,06	0,34	0,51	<b>0,73</b>	0,22
USO1	0,33	0,13	0,73	0,53	0,44	0,35	0,56	0,42	0,36	<b>0,93</b>
USO2	0,27	0,10	0,63	0,55	0,39	0,28	0,50	0,40	0,34	<b>0,94</b>
USO3	0,29	0,13	0,71	0,59	0,44	0,33	0,55	0,39	0,31	<b>0,97</b>



## Referencias

- Agrawal, A., Gans, J., & Goldfarb, A. (2019). *Máquinas predictivas: La sencilla economía de la inteligencia artificial*. Reverte-Management.
- Alderete, M. V., Jones, C., & Morero, H. A. (2014). *Factores explicativos de la adopción de las TIC en las tramas productivas automotriz y siderúrgica de Argentina*. <https://doi.org/10.14482/pege.37.7019>
- Alfonso, M., Cazorla, M., Colomina, O., Escolano, F., & Lozano, M. (2003). *Inteligencia artificial: modelos, técnicas y áreas de aplicación*. Thomson.
- Arias, V., Salazar, J., Gariciano, C., Contreras, J., Chacón, G., Chacín-González, M., ... Bermúdez-Pirela, V. (2019). Una introducción a las aplicaciones de la inteligencia artificial en Medicina: Aspectos históricos. En *Revista Latinoamericana de Hipertensión*. Cooperativa servicios y suministros 212518 RS.
- Arones, C. Q., León Fernández, C., & Moquillaza Vizarreta, A. (s. f.). ACCEPTANCE OF INTERNET SERVICE IN PERUVIAN HOTELS BASED ON UTAUT2. «CASA ANDINA» CASE. <https://doi.org/10.17993/3ctic.2019.81.12-35>
- Astigarraga, E. (2008). El método delphi. *San Sebastián: Universidad de Deusto*.
- Berge, S. H. (2018). *Rise of the Chatbots: Trust in Artificial Intelligence During Extreme Weather Events*.
- Bishop, C. M. (2016). *Pattern Recognition and Machine Learning*. En *Information Science and Statistics*. Springer New York.
- Bouwman, H., van den Hooff, B., van de Wijngaert, L., & van Dijk, J. (2005). Information and communication technology in organizations: Adoption, implementation, use and effects. En *Information and Communication Technology in Organizations: Adoption, Implementation, Use and Effects*. <https://doi.org/10.4135/9781446211519>
- Cabrera, J. P., & Villarejo, Á. F. (2018). FACTORES QUE AFECTAN A LA ADOPCIÓN DEL BIG DATA COMO INSTRUMENTO DE MARKETING EN EMPRESAS ESPAÑOLAS.
- Cabrero, J., & Barroso, J. (2013). La utilización del juicio de experto para la evaluación de TIC: el Coeficiente de competencia experta. *Bordón. Revista de Pedagogía*, 65(2), 25-38. <https://doi.org/10.13042/brp.2013.65202>
- Cabrero, J., & Infante, A. (2014). Empleo del método Delphi y su empleo en la investigación en comunicación y educación. *Edutec. Revista Electrónica de Tecnología Educativa*, (48), a272-a272.

<https://doi.org/10.21556/EDUTECH.2014.48.187>

- Cabrero, J., & Llorente, C. (2013). La aplicación del juicio de experto como técnica de evaluación de las tecnologías de la información y comunicación (TIC). En *Eduweb. Revista de Tecnología de Información y Comunicación en Educación* (Vol. 7).
- Cárdenas, J. M. (2018). *EL MACHINE LEARNING A TRAVÉS DE LOS TIEMPOS, Y LOS APORTES A LA HUMANIDAD DENNIYE HINESTROZA RAMÍREZ*.
- CEPAL. (2018). *Datos, algoritmos y políticas: la redefinición del mundo digital*. Santiago.
- Cerón, K. J., & Arboleda, H. F. (2018). Model of strategic relationships between organizational and technical factors in colombian software factories. *Informacion Tecnologica*, 29(3), 29-38. <https://doi.org/10.4067/S0718-07642018000300029>
- Chew, Y. J., Wong, K.-S., & Ooi, S. Y. (2017). Privacy protection in machine learning: The state-of-the-art for a private decision tree. En *Security and Authentication: Perspectives, Management and Challenges* (pp. 13-39).
- Christopher, M., Payne, A., & Ballantyne, D. (1994). *Marketing relacional: integrando la calidad, el servicio al cliente y el marketing*. D{\i}az de Santos.
- D'Addario, M. (2019). *Inteligencia Artificial: Tratados, Aplicaciones, Usos y Futuro*. Amazon Digital Services LLC - Kdp Print Us.
- Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly: Management Information Systems*, 13(3), 319-339. <https://doi.org/10.2307/249008>
- De León Sigg, M., Luis, J., Cisneros, V., Reyes, S. V., Antonio, J., & Salcedo, R. (2014). *Explicación de la Adopción de Tecnologías de Información en Pequeñas Empresas Usando el Modelo del Usuario Perezoso: un Caso de Estudio*. <https://doi.org/10.4304/risti.e1.91-104>
- de Liaño, B. G. G., & Pascual-Ezama, D. (2012). La metodología Delphi como técnica de estudio de la validez de contenido. *Anales de Psicología*, 28(3), 1011-1020. <https://doi.org/10.6018/analesps.28.3.156211>
- Díaz, B., Gómez, J., García, J., Melo, H., & Sanabria, F. (2017). La contribution des initiatives des technologies de l'information dans les organisations: Une revue de la littérature. *Innovar*, 27(66), 41-55. <https://doi.org/10.15446/innovar.v27n66.66710>
- Endeavor, & Everis. (2018). *El impacto de la inteligencia artificial en el emprendimiento*. México.
- Eslava, R., Cuadrado, A., & García, E. (2010). *Evaluación de la satisfacción de las necesidades de información de los usuarios contables con el análisis DELPHI ; Evaluation of the satisfaction of accounting users' information needs with the DELPHI analysis*.
- Faggella, D. (2020). What is Machine Learning? Recuperado 12 de agosto de 2020, de

- Emerj website: <https://emerj.com/ai-glossary-terms/what-is-machine-learning/>
- Fang, Z., & George, K. M. (2017). Application of Machine Learning: An Analysis of Asian Options Pricing Using Neural Network. *Proceedings - 14th IEEE International Conference on E-Business Engineering, ICEBE 2017 - Including 13th Workshop on Service-Oriented Applications, Integration and Collaboration, SOAIC 2017*, 142-149. <https://doi.org/10.1109/ICEBE.2017.30>
- Fernandez-Luque, L., & Imran, M. (2018). Humanitarian health computing using artificial intelligence and social media: A narrative literature review. *International Journal of Medical Informatics*, 114, 136-142.
- Fernández, P. (2015). *Análisis de los factores de influencia en la adopción de herramientas colaborativas basadas en software social. Aplicación a entornos empresariales*.
- Fernández Robin, C., McCoy, S., Yáñez Sandivari, L., & Yáñez Martínez, D. (2014). *Technology Acceptance Model: Worried about the Cultural Influence?* [https://doi.org/10.1007/978-3-319-07293-7\\_59](https://doi.org/10.1007/978-3-319-07293-7_59)
- Flanders, N. A., Fishbein, M., & Ajzen, I. (1975). *Belief, Attitude, Intention, and Behavior: An Introduction to Theory and Research*. En *Addison-Wesley series in social psychology*. Addison-Wesley Publishing Company.
- Fornell, C., & Larcker, D. F. (1981). Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research*, 18(1), 39. <https://doi.org/10.2307/3151312>
- Fuentes-Barassi, C. (2010). *Maquinaria computacional e Inteligencia Alan Turing, 1950. Traducción*. Santiago.
- Gao, J., Wang, W., Zhang, M., Chen, G., Jagadish, H. V, Li, G., ... Zhou, J. (2018). *PANDA: Facilitating Usable AI Development*.
- García, M. E., & Lena, F. J. (2018). Aplicación del metodo delphi en el diseño de una investigación cuantitativa sobre el fenómeno FABLAB. *Empiria. Revista de metodología de ciencias sociales*, 0(40), 129. <https://doi.org/10.5944/empiria.40.2018.22014>
- Gefen, D., Straub, D., & Boudreau, M.-C. (2000). Structural Equation Modeling and Regression: Guidelines for Research Practice. *Communications of the Association for Information Systems*, 4. <https://doi.org/10.17705/1CAIS.00407>
- Grandon, E. E., Aravena, A., Araya, S., Ramirez-Correa, P., & Alfaro-Perez, J. (2018). Internet of Things: Factors that influence its adoption among Chilean SMEs. *Iberian Conference on Information Systems and Technologies, CISTI, 2018-June*, 1-6. <https://doi.org/10.23919/CISTI.2018.8399183>
- Grandón, E. E., Nasco, S. A., & Mykytyn, P. P. (2011). Comparing theories to explain e-commerce adoption. *Journal of Business Research*, 64(3), 292-298. <https://doi.org/10.1016/j.jbusres.2009.11.015>

- Ha, D. (2017). Google AI Blog: Teaching Machines to Draw. Recuperado 12 de agosto de 2020, de Google AI Blog website: <https://ai.googleblog.com/2017/04/teaching-machines-to-draw.html>
- Haenlein, M., & Kaplan, A. M. (2004). A Beginner's Guide to Partial Least Squares Analysis. *Understanding Statistics*, 3(4), 283-297. [https://doi.org/10.1207/s15328031us0304\\_4](https://doi.org/10.1207/s15328031us0304_4)
- Hair, J., Hult, G. T., Ringle, C., & Sarstedt, M. (2014). A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM). *2014 Faculty Bookshelf*.
- Hair, Joe F., Ringle, C. M., & Sarstedt, M. (2011). PLS-SEM: Indeed a silver bullet. *Journal of Marketing Theory and Practice*, 19(2), 139-152. <https://doi.org/10.2753/MTP1069-6679190202>
- Hair, Joseph F, Anderson, R. E., Tatham, R. L., Black, W. C., & others. (1999). *Análisis multivariante* (Vol. 491). Prentice Hall Madrid.
- Henseler, J. (2017). Bridging Design and Behavioral Research With Variance-Based Structural Equation Modeling. *Journal of Advertising*, 46(1), 178-192. <https://doi.org/10.1080/00913367.2017.1281780>
- Holguín-Ontiveros, E. P. (2015). *Aspectos de la Cultura Organizacional que Influyen en el Proceso de Implantación de Sistemas de Información en las Organizaciones*. Bogotá.
- Huckvale, K., Wang, J. C., Majeed, A., & Car, J. (2019). *Digital health at fifteen : more human (more needed)*.
- International, D., & Brackett, M. H. (2015). *The DAMA Guide to the Data Management Body of Knowledge (DAMA-DMBOK) Spanish Edition: Versión en español de la Guía DAMA de los fundamentos para la gestión de datos (DAMA-DMBOK)*. Technics Publications.
- Jiménez, F. (2017). La deuda pendiente de la banca con la tecnología financiera. *El Colombiano*.
- Kaldi, A., Aghaie, A., & Khoshalhan, F. (2008). KMS adoption in organizations. *2008 IEEE International Conference on Industrial Engineering and Engineering Management, IEEM 2008*, 37-41. <https://doi.org/10.1109/IEEM.2008.4737828>
- Kanak, A., & Sogukpinar, I. (2017). BioTAM: a technology acceptance model for biometric authentication systems. *IET Biometrics*, 6(6), 457-467. <https://doi.org/10.1049/iet-bmt.2016.0148>
- Katz, R., & Callorda, F. (2017). *Hacia la transformación digital de América Latina y el Caribe: El Observatorio CAF del Ecosistema Digital*.
- Katz, R. L. (2017). *EL OBSERVATORIO DE LA ECONOMÍA DIGITAL DE COLOMBIA*. Bogotá.



- Kessler, S. K., & Martin, M. (2017). *How do potential users perceive the adoption of new technologies within the field of Artificial Intelligence and Internet-of-Things? - A revision of the UTAUT 2 model using Voice Assistants*. Sweden, Europe: Lunds universitet/Företagsekonomiska institutionen.
- Kitchenham, B. (2004). *Procedures for Performing Systematic Reviews*.
- Kraus, M., & Feuerriegel, S. (2017). Decision support from financial disclosures with deep neural networks and transfer learning. *Decision Support Systems*, 104, 38-48. <https://doi.org/10.1016/j.dss.2017.10.001>
- Landeta, J. (2002). *El método Delphi: una técnica de previsión para la incertidumbre*. Barcelona: Ariel.
- Latorre, P., & Tovar, M. A. (2019). *Adopción de la tecnologías digitales en la industria pyme hamburguesa en Bogotá*.
- Leitner, M., & Rinderle-Ma, S. (2014). A systematic review on security in Process-Aware Information Systems – Constitution, challenges, and future directions. *Information and Software Technology*, 56(3), 273-293. <https://doi.org/10.1016/J.INFSOF.2013.12.004>
- Lima-Faria, L. H., Giuliani, A. C., Cavazos-Arroyo, J., & Kassouf-Pizzinatto, N. (2016). Moderando entre géneros: una evaluación de aceptación y uso de internet en smartphones por medio del modelo UTAUT2. *Cuadernos del CIMBAGE, ISSN-e 1669-1830, N°. 18, 2016, págs. 29-55, (18), 29-55*.
- López-Bonilla, L. M., & López-Bonilla, J. M. (2011). Los modelos de adopción de tecnologías de la información desde el paradigma actitudinal. *Cadernos EBAPE.BR*, 9(1), 176-196. <https://doi.org/10.1590/s1679-39512011000100011>
- Marr, B. (2017, julio 13). The Biggest Challenges Facing Artificial Intelligence (AI) In Business And Society. *Forbes*.
- Martínez, M., & Fierro, E. (2018). Aplicación de la técnica PLS-SEM en la gestión del conocimiento: un enfoque técnico práctico / Application of the PLS-SEM technique in Knowledge Management: a practical technical approach. *RIDE Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, 8(16), 130-164. <https://doi.org/10.23913/ride.v8i16.336>
- Mayer, R. C., Davis, J. H., & Schoorman, F. D. (1995). An Integrative Model of Organizational Trust. *The Academy of Management Review*, 20(3), 709. <https://doi.org/10.2307/258792>
- Mingers, J., & Brocklesby, J. (1997). *Multimethodology: Towards a Framework for Mixing Methodologies*. En *Warwick Business School research papers*. Warwick Business School Research Bureau.
- Mingers, J., & Gill, A. (1997). *Multimethodology: Towards Theory and Practice and Mixing and Matching Methodologies*. Wiley.

- Mingers, J., Mutch, A., & Willcocks, L. (2013). *CRITICAL REALISM IN INFORMATION SYSTEMS RESEARCH*.
- Ministerio de Educación, E. (2017). *El Español como lengua para la innovación profesional. Artículos seleccionados del VI Congreso Internacional de Español para Fines Específicos (CIEFE)*. Ministerio de Educación.
- Narayan, O., Qazi, M. A., & Kannan, R. (2018). *Benchmarking Supervised Learning Frameworks for Engineering Highly Scalable Intelligent Systems*.
- Naylor, C. D. (2018). On the Prospects for a (Deep) Learning Health Care System. *JAMA*, 320(11), 1099-1100. <https://doi.org/10.1001/jama.2018.11103>
- Nilsson, J., & Sandin, F. (2018). Semantic Interoperability in Industry 4.0: Survey of Recent Developments and Outlook. *2018 IEEE 16th International Conference on Industrial Informatics (INDIN), Industrial Informatics (INDIN), 2018 IEEE 16th International Conference on*, p. 127. <https://doi.org/10.1109/INDIN.2018.8471971>
- Norman, A. T., & Bolivar, S. (2019). *Aprendizaje Automático En Acción: Un Libro Para El Lego, Guía Paso A Paso Para Los Novatos*. Tektime.
- OCDE. (2011). OCDE Definición Marco de Inversión Extranjera Directa. En *OCDE Definición Marco de Inversión Extranjera Directa*. <https://doi.org/10.1787/9789264094475-es>
- Osorio, O. P., & Peña, F. L. (2015). *Captura de movimiento utilizando el kinect para el control de una plataforma robotica controlada de forma remota por medio de seguimiento de los puntos de articulación del cuerpo*.
- Ovanessoff, A., & Plastino, E. (2017). *Cómo la inteligencia artificial crecimiento en Sudamérica*.
- Palma, J. M., González, S. E., & Cortés, J. A. (2019). Learning management systems in mobile devices: Evidence of acceptance at a public university in Mexico. En *Innovación Educativa, ISSN-e 1665-2673, Vol. 19, N° 79, 2019, págs. 35-56* (Vol. 19). Instituto Politécnico Nacional.
- Parada, J. (2004). Realismo crítico en investigación en ciencias sociales: una introducción. *Investigación & Desarrollo*, 12(2), 396-429.
- Parra, J. D. (2016). Realismo crítico: una alternativa en el análisis social. *Revista Sociedad y Economía - CIDSE*, (31), 11-286.
- Pearson, J. M., & Grandon, E. E. (2006). An empirical study of factors that influence E-commerce adoption/non-adoption in small and medium sized businesses. *Journal of Internet Commerce*, 4(4), 1-21. [https://doi.org/10.1300/J179v04n04\\_01](https://doi.org/10.1300/J179v04n04_01)
- ProMéxico. (2017). *Machine Learning. Inteligencia artificial que está transformando al mundo*. México.
- Ramirez-Anormaliza, R., Guevara-Viejo, F., D'Armas Regnault, M., Pena-Holguin, R.,

- Farias-Lema, R., Bravo-Duarte, F., ... Castelo-Gonzalez, J. (2017). Análisis Multivariante: Teoría y práctica de las principales técnicas Autores. En *Repositorio de la Universidad Estatal de Milagro*.
- Ramírez-Correa, P. (2014). Mobile internet usage in Chile: Exploring the antecedents of its acceptance at the individual level. *Ingeniare*, 22(4), 560-566. <https://doi.org/10.4067/S0718-33052014000400011>
- Ramírez-Correa, P., Grandón, E., & Painén-Aravena, G. (2017). *Efecto de los rasgos de personalidad en el uso de las tecnologías de información*.
- Rana, R. (2015). *Software Defect Prediction Techniques in Automotive Domain: Evaluation, Selection and Adoption*. Sweden, Europe.
- Rana, R, Staron, M., Berger, C., Hansson, J., Nilsson, M., & Meding, W. (2014). The Adoption of Machine Learning Techniques for Software Defect Prediction: An Initial Industrial Validation. *COMMUNICATIONS IN COMPUTER AND INFORMATION SCIENCE*, (466), 270. Cham; Springer.
- Rana, Rakesh, Staron, M., Hansson, J., Nilsson, M., & Meding, W. (2015). A framework for adoption of machine learning in industry for software defect prediction. *2015 International Conference on Computing & Communications Technologies (ICCT)*, 383.
- Reguant, M., & Torrado, M. (2016). El mètode Delphi. *REIRE Revista d'Innovació i Recerca en Educació*, 9(1), 87-102.
- Revista Dinero. (2019, noviembre 19). Los duros en machine learning también están en Colombia. Recuperado 25 de julio de 2020, de Revista Dinero website: <https://www.dinero.com/emprendimiento/articulo/que-colombianos-estan-desarrollando-herramientas-de-machine-learning/278988>
- Riaño, C. E., & Palomino, M. (2015). *Design and development of a questionnaire delphi method chord with virtual laboratories for selecting (LV) ; Diseño y elaboración de un cuestionario acorde con el método Delphi para seleccionar laboratorios virtuales (LV)*.
- Riaño, J. S. (2018). *Relaciones entre el conocimiento organizativo y la apropiación de las Tecnologías de la información. Un análisis desde la literatura académica Relaciones entre el conocimiento organizativo y la apropiación de las Tecnologías de la información View project*. <https://doi.org/10.13140/RG.2.2.35101.15848>
- Ridley, D. (2008). *The literature review : a step-by-step guide for students*. SAGE.
- Rogers, E. M. (2003). *Diffusion of Innovations, 5th Edition*. Free Press.
- Russell, S. J., Norvig, P., & Gutiérrez, R. B. (1996). *Inteligencia artificial: un enfoque moderno*. En *Colección de Inteligencia Artificial*. Pearson Educación.
- Russu, P., Demontis, A., Biggio, B., Fumera, G., & Roli, F. (2016). *Secure Kernel Machines against Evasion Attacks*. Italy, Europe: Association for Computing

Machinery, Inc.

- Salahshour, M., Nilashi, M., & Mohamed, H. (2018). Information technology adoption: a review of the literature and classification. *Universal Access in the Information Society*, 17(2), 361-390. <https://doi.org/10.1007/s10209-017-0534-z>
- Salesforce. (2017). ¿Qué es la inteligencia artificial? - Blog de Salesforce. Recuperado 12 de agosto de 2020, de <https://www.salesforce.com/mx/blog/2017/6/Que-es-la-inteligencia-artificial.html>
- Samuel, A. L. (1967). Some Studies in Machine Learning Using the Game of Checkers. II-Recent Progress. *IBM Journal*, 601-617.
- Sepúlveda-López, J. J. (2014). *Evaluación del Impacto de Proyectos Tecnológicos Ambientalizados: Construcción de Ciudadanía por medio de Inclusión Digital*.
- Shmueli, G., & Koppius, O. R. (2011, septiembre). Predictive analytics in information systems research. *MIS Quarterly: Management Information Systems*, Vol. 35, pp. 553-572. <https://doi.org/10.2307/23042796>
- Stead, W. W. (2018). Clinical Implications and Challenges of Artificial Intelligence and Deep Learning. *JAMA*, 320(11), 1107-1108. <https://doi.org/10.1001/jama.2018.11029>
- Studio SAP. (2018, agosto). Analíticas predictivas y machine learning: potenciar la empresa inteligente. Recuperado 25 de julio de 2020, de <https://www.sap.com/latinamerica/documents/2018/12/369cea64-2e7d-0010-87a3-c30de2ffd8ff.html?infl=63f230fa-59a5-4e61-8129-b10646e61b9b?campaigncode=CRM-XL20-PLT-ANPREML&sap-outbound-id=F6F8DBB566462AEF4953844019AE97183A950E81&campaigncode=CRM-XL20-PLT-ANPREML&source=nurture-smc>
- Stumpe, M., & Peng, L. (2017). Google AI Blog: Assisting Pathologists in Detecting Cancer with Deep Learning. Recuperado 12 de agosto de 2020, de Google AI Blog website: <https://ai.googleblog.com/2017/03/assisting-pathologists-in-detecting.html>
- Taigman, Y., Ming, Y., Ranzato, M. A., & Wolf, L. (2014). *DeepFace: Closing the Gap to Human-Level Performance in Face Verification*.
- Teigens, V. (s. f.). *Inteligencia Artificial General*. En *Inteligencia artificial: la cuarta revolución industrial*. Cambridge Stanford Books.
- Tw Google. (2018). Cómo el Machine Learning está transformando el marketing de aplicaciones. Recuperado 12 de agosto de 2020, de Think whit Google website: <https://www.thinkwithgoogle.com/intl/es-419/recursos-y-herramientas/aplicaciones/como-el-machine-learning-esta-transformando-el-marketing-de-aplicaciones/>
- Urbach, N., & Ahlemann, F. (2010). Structural Equation Modeling in Information Systems Research Using Partial Least Squares. *Journal of Information Technology Theory*

- and Application (JITTA)*, 11(2).
- Varela, M., Díaz, L., & García, R. (2012). Descripción y usos del método Delphi en investigaciones del área de la salud / Description and uses of the Delphi method in health sciences research. *Investigación en educación médica*, (2), 90.
- Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. *MIS Quarterly: Management Information Systems*, 27(3), 425-478. <https://doi.org/10.2307/30036540>
- Venkatesh, V., Thong, J. Y. L., & Xu, X. (2012). Consumer acceptance and use of information technology: Extending the unified theory of acceptance and use of technology. *MIS Quarterly: Management Information Systems*, 36(1), 157-178. <https://doi.org/10.2307/41410412>
- Yazdi, M. T., Motallebzadeh, K., Ashraf, H., & Baghaei, P. (2017). A latent variable analysis of continuing professional development constructs using PLS-SEM modeling PUBLIC INTEREST STATEMENT. *Cogent Education*, 9, 1355610. <https://doi.org/10.1080/2331186X.2017.1355610>