



**Análisis de Factores que Influyen en la
Implementación de Inteligencia Artificial para
Creación de Contenido en Redes Sociales: Un
Enfoque desde la Metodología UTAUT2**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL
INDUSTRIAL

AUTOR:

BASTIÁN GÓMEZ CÁCERES

PROFESOR GUÍA:

OSCAR SAAVEDRA

SANTIAGO DE CHILE, 27 DE AGOSTO DE 2024



Dedicatoria

A mi familia, pilar fundamental de mi vida. Gracias por su amor incondicional, su paciencia infinita, por hacerme la persona que soy hoy en día y su apoyo constante en cada paso de esta carrera universitaria.

A mis amigos y amigas, compañeros de risas, desvelos y desafíos. Su amistad ha sido un regalo invaluable que ha hecho de esta experiencia universitaria algo inolvidable.

A todos aquellos que creyeron en mí, incluso cuando yo dudaba. Sus palabras de aliento y gestos de apoyo han sido la fuerza que me impulsó a perseverar y alcanzar esta meta.

Este logro no es solo mío, sino de todos ustedes que me acompañaron en este viaje. Gracias por ser parte de mi vida y por ayudarme a cumplir con esta meta tan importante.



Agradecimientos

Al concluir esta importante etapa de mi vida académica, deseo expresar mi más profunda gratitud a quienes me han acompañado y apoyado en este camino.

Extiendo mi reconocimiento a la Universidad Técnica Federico Santa María, institución que me brindó no solo una formación académica de excelencia, sino también un ambiente propicio para mi crecimiento personal y profesional.

A todos los profesores que contribuyeron a mi formación a lo largo de la carrera, les expreso mi sincero agradecimiento por compartir sus conocimientos y experiencias. Quiero agradecer especialmente al profesor Oscar Saavedra y Eloy Alvarado, cuya guía, dedicación y apoyo fueron fundamentales durante todo el proceso de elaboración de esta tesis. Su experiencia y consejos han sido invaluable para llevar a buen término este trabajo.

A todos, muchas gracias.



Resumen

Para esta investigación se examinó la adopción y uso de la inteligencia artificial (IA) en la creación de contenido para redes sociales, un tema de creciente relevancia debido al auge exponencial del uso de la IA en diversos ámbitos durante los últimos años. El estudio utiliza como modelo base el propuesto por la Teoría unificada de aceptación y uso de la tecnología 2 (UTAUT 2, por sus siglas en inglés), empleando un análisis factorial confirmatorio para evaluar las hipótesis planteadas sobre los diversos factores y moderadores que influyen en este fenómeno.

La investigación se fundamenta en un enfoque cuantitativo, recolectando datos de una muestra predominantemente joven de usuarios de redes sociales. El análisis de los datos reveló que la Expectativa de Rendimiento, la Influencia Social y el Hábito son factores significativos que afectan positivamente la Intención de Uso de la IA para la creación de contenido. Por otro lado, las Condiciones Facilitadoras, el Hábito y la Intención de uso se identificaron como factores determinantes que influyen positivamente en la Conducta de Uso real.

El modelo propuesto demostró un ajuste generalmente satisfactorio a los datos observados con la mayoría de los indicadores dentro de los rangos buenos y aceptables. La aplicación del análisis factorial confirmatorio permitió validar algunas de las hipótesis relacionadas con los constructos principales del modelo UTAUT2 en el contexto específico de la IA para la creación de contenido en redes sociales. Sin embargo, se notó que la inclusión de variables moderadoras al modelo no mejoró significativamente los valores del ajuste del modelo, sugiriendo áreas para futuras investigaciones.

Basándose en estos hallazgos, la tesis propone recomendaciones para desarrolladores de tecnologías de IA y usuarios finales. Para los desarrolladores, se enfatiza la importancia de mejorar el rendimiento percibido, diseñar interfaces intuitivas y proporcionar condiciones facilitadoras adecuadas. Para los usuarios, se recomienda una adopción estratégica, la integración de las herramientas en las rutinas diarias y el aprovechamiento de las condiciones facilitadoras disponibles.



Se concluye sugiriendo direcciones para futuras investigaciones, incluyendo la necesidad de abordar el sesgo de la muestra, extender el estudio a diversos contextos y sectores socioeconómicos, y realizar estudios longitudinales sobre la implementación a largo plazo de estas tecnologías.

Este estudio contribuye a la comprensión de cómo se adopta y utiliza la IA en el ámbito de la creación de contenido para redes sociales, un área de rápido crecimiento e innovación. Los resultados proporcionan datos valiosos para el desarrollo y la implementación efectiva de estas tecnologías en el ecosistema digital en constante evolución, reflejando la importancia crítica de entender los factores que impulsan la adopción de la IA en la era digital actual.



Contenido

Dedicatoria.....	2
Agradecimientos	3
Resumen.....	4
Capítulo I: Introducción	8
Contexto.....	8
Justificación del problema	9
Objetivos	10
Objetivo General	10
Objetivos Específicos.....	10
Supuestos	11
Capítulo II: Estado del Arte y Alcance	12
Estado actual del conocimiento.....	12
Propuesta de valor.....	15
Alcance de la memoria.....	16
Capítulo III: Marco Teórico.....	17
Web social.....	17
Redes sociales	18
Redes sociales en Latinoamérica	19
Situación en Chile	20
Redes sociales más usadas en Chile.....	22
Uso de redes sociales por edades en Chile.....	23
Cómo nos referimos a la Inteligencia Artificial (IA)	24
Funcionamiento de la IA.....	25
Principales Capacidades de la IA.....	28
Inteligencia artificial generativa (GenIA)	30
Inteligencia Artificial y Redes Sociales	31
Modelos y Teorías de aceptación de nueva tecnológica	33
Teoría de acción razonada (TRA).....	33
Modelo de aceptación de tecnologías (TAM)	34
Modelo de aceptación de tecnologías 2 (TAM2).....	35
Teoría unificada de la aceptación y uso de la tecnología (UTAUT).....	36
Teoría unificada de la aceptación y uso de la tecnología 2 (UTAUT2).....	38
Modelo de ecuaciones estructurales (SEM).....	40
Variables observables y latentes	41



Variables moderadoras y mediadoras	41
Modelo general de ecuaciones estructurales	42
Diagrama de senderos	43
Pasos para la modelación de ecuaciones estructurales	44
Capítulo IV: Propuesta de metodología	52
Hipótesis	52
Capítulo V: Marco metodológico	58
Método recolección de datos.....	59
Diseño de muestreo.....	61
Público objetivo	61
Localización de la muestra.....	61
Técnica de muestro y tamaño de la muestra	61
Instrumento de investigación	64
Análisis de datos	65
Análisis descriptivo.....	65
Validación de datos.....	66
Análisis SEM	67
Capítulo VI: Estudio empírico y resultados	68
Validación de datos etapa de análisis preventivo.....	68
Análisis base de datos recolectada	74
Análisis descriptivo.....	74
Validación de datos.....	76
Análisis Multicolinealidad	77
Análisis SEM	79
Capítulo VII: Conclusiones generales.....	92
Resultados	92
Moderadores	93
Ajuste de bondad.....	94
Recomendaciones.....	95
Futuras investigaciones.....	98
Referencias.....	100



Capítulo I: Introducción

Contexto

La inteligencia artificial (IA) ha experimentado un crecimiento exponencial en todo el mundo, su uso ha aumentado de manera drástica durante el año 2023 después de años de cambios poco significativos, transformando así múltiples sectores de la sociedad (McKinsey Global Institute, 2024). En la era digital actual, caracterizada por la disrupción constante, la abundancia de datos y la aceleración de los ciclos de innovación “resulta fundamental que los países en vías de desarrollo implementen un masivo plan de formación en habilidades digitales” (Neira, 2020).

En este entorno de acelerado desarrollo, una de las aplicaciones de la IA que más ha permeado socialmente y que más impacto y controversia ha causado es la destinada a la creación automatizada de contenido. Esta ha acelerado su crecimiento en capacidad tecnológica y está alcanzando un grado de sofisticación antes difícil de imaginar (Franganillo, 2023), lo que ha llevado a ganar una aceptación y popularidad significativas en la sociedad en general (Wang & Zhang, 2023). La producción de contenido para redes sociales emerge como un sector particularmente receptivo a la implementación de soluciones basadas en IA debido a la gran cantidad de gente que utiliza redes sociales, su facilidad de acceso y su practicidad a la hora de llegar a una gran cantidad de persona. A medida que las organizaciones y las personas buscan mantenerse actualizados en un entorno cada vez más digitalizado, la adopción de la IA se ha convertido en una idea innovadora y atractiva. “La innovación es vital para obtener una ventaja competitiva” (Ince, Imamoglu, & Turkcan, 2016). La implementación y complementación de la Inteligencia Artificial con las estrategias y la creación de contenido para redes sociales está redefiniendo la forma en que las marcas y los creadores interactúan con sus audiencias. Un estudio de (Hootsuite, 2023) reveló que el 52% de los profesionales de marketing planean aumentar su inversión en herramientas de IA para la creación y gestión de contenido en redes sociales para el año 2024. Esta tendencia subraya la creciente confianza en la capacidad de la IA para complementar y potenciar los esfuerzos humanos en este ámbito. “Hay que tomar en consideración que la IA no será una herramienta opcional para los negocios.” (García, Pazmiño, Armijos, Sosa, & Reinoso., 2018)



Justificación del problema

Ante lo expuesto anteriormente, es innegable que la inteligencia artificial está creciendo a pasos agigantados emergiendo como un aliado prometedor para la creación de contenido en redes sociales debido a sus capacidades únicas que logran complementar y potenciar las habilidades humanas, es por esto que nace la necesidad de conocer y averiguar más sobre esta nueva tecnología. Es fundamental identificar y comprender su funcionamiento, sus principales capacidades y como estas pueden complementar y potenciar la creación de contenido para aprovechar al máximo los beneficios, pero la problemática principal de esta investigación es ¿Cuáles son las variables que afectan o influyen en su uso? y ¿Por qué esta nueva tecnología ha logrado tener este éxito? Para conocer la respuesta a estas preguntas es necesario realizar un análisis de los factores que influyen en la intención de uso debido a que existe una brecha en la comprensión de cuáles son los factores que facilitan o barreras que obstaculizan su implementación y cómo se puede aprovechar de manera óptima esta colaboración para lograr una sinergia.

“Con el fin de analizar el comportamiento del usuario con respecto a la adopción de tecnologías innovadoras, la literatura científica ha desarrollado variadas teorías de la conducta y modelos de intención durante las últimas cuatro décadas” (F. Muñoz-Leiva, 2017). Dentro del contexto enfocado al consumidor, fue desarrollado por (Venkatesh, Thong, & Xu, 2012) el modelo UTAUT2 (Modelo de Aceptación y Uso de Tecnología Unificado, por sus siglas en inglés) el cual es una modificación al modelo original UTAUT propuesto por (Venkatesh, Morris, Davis, & Davis, 2003) desarrollado originalmente para explicar la aceptación y el uso de la tecnología de los empleados en un contexto empresarial. El modelo UTAUT2 fue desarrollado identificando constructos y relaciones adicionales claves para ser integradas en este modelo UTAUT y adaptándolo a un contexto de uso del consumidor. El modelo UTAUT2 ofrece un marco conceptual robusto para examinar cómo los creadores de contenido en redes sociales adoptan y aceptan las herramientas de inteligencia artificial. Este modelo, originalmente desarrollado para entender la aceptación de tecnologías de información, puede ser adaptado al contexto específico de la IA en la creación de contenido digital.



La investigación basada en este contexto específico puede proporcionar información valiosa tanto para los desarrolladores de tecnología o como base para futuras innovaciones en el ámbito del marketing digital y la comunicación, permitiendo generar un cuerpo de conocimiento sobre el comportamiento del consumidor tecnológico en Chile, lo cual es esencial para el desarrollo de estrategias efectivas que ayuden a anticipar y abordar las necesidades y preocupaciones de los consumidores chilenos de IA en la creación de contenido para redes sociales.

Objetivos

Objetivo General

Examinar y modelar el comportamiento de los consumidores de inteligencia artificial para la creación de contenido en redes sociales en Chile mediante la aplicación de un modelo adaptado de aceptación tecnológica y un estudio de campo basado en encuestas. Se busca identificar los factores más influyentes y las motivaciones principales que impulsan a los usuarios chilenos a utilizar esta tecnología.

Objetivos Específicos

- Identificar el modelo de aceptación de nuevas tecnologías que mejor se adecue al contexto del uso de la inteligencia artificial para crear contenido en redes sociales, generando una base teórica y conceptual de los diferentes modelos analizados.
- Recopilar datos sobre el nivel del uso de la tecnología a través de encuestas, con el objetivo de obtener información sobre las actitudes, intención de uso y experiencias de los consumidores.
- Identificar las principales variables que influyen en la intención de uso de la inteligencia artificial para la creación de contenido en redes sociales mediante el análisis estadístico de las hipótesis planteadas en el modelo.
- Generar conclusiones y proponer recomendaciones a través del análisis de los resultados de la aplicación del modelo, con el fin de optimizar la implementación y adopción de esta tecnología en futuras innovaciones en el sector de la creación de contenido digital.



Supuestos

Se presenta un listado exhaustivo de lo que es considerado como contenido generado por inteligencia artificial y utilizado por las personas para las redes sociales:

- **Textos y copys:** Dentro de este contexto existe, la generación de títulos atractivos, la redacción de publicaciones para el feed, tweets/post cortos, pies de foto, títulos, encabezados, hashtags relevantes, descripciones de productos, etc.
- **Imágenes:** Ya sea fotos generadas por IA, ilustraciones digitales, memes, banners, portadas, filtros y efectos visuales, etc.
- **Videos:** Generación de clips cortos tipo TikTok o Reels, animaciones, edición automática de metraje existente, generación de subtítulos, sincronización de labios en videos, etc.
- **Audio:** Conversión de texto a voz para narración, efectos de sonido, música de fondo, etc.
- **Análisis y estrategia:** Sugerencias de temas tendencia, recomendaciones de horarios de publicación, análisis de sentimiento de comentarios, predicción de engagement, etc.
- **Interacción con usuarios:** Chatbots para respuestas automáticas, personalización de respuestas, moderación de comentarios, etc.
- **Optimización de contenido:** Adaptación de contenido para diferentes plataformas, sugerencias de palabras clave SEO.
- **Contenido interactivo:** Juegos simples, filtros de realidad aumentada, etc.
- **Traducción y localización:** Adaptación de contenido a diferentes idiomas y culturas.
- **Curación de contenido:** Selección de contenido relevante de otras fuentes, resúmenes de artículos o noticias, etc.
- **Personalización:** Contenido adaptado a segmentos de audiencia específicos.
- **Programación y automatización:** Calendarios de publicación automáticos, reciclaje inteligente de contenido antiguo, etc.



Además, en el diseño y ejecución de este estudio sobre la adopción y aceptación de tecnologías, se asume que los participantes en la encuesta proporcionarán información verídica, basada en sus experiencias reales con la tecnología en cuestión. Esta suposición es fundamental para la integridad del estudio. Se garantiza la confidencialidad de los datos personales de los encuestados, lo cual se espera que fomente respuestas honestas y precisas. Además, se han establecido medidas técnicas para prevenir respuestas múltiples de un mismo participante, asegurando así que cada participante no responda la encuesta en más de una oportunidad.

Estos principios metodológicos son esenciales para obtener un conjunto de datos confiable y representativo. Solo a través de información auténtica y diversa se podrá realizar un análisis profundo y significativo sobre el uso de la inteligencia artificial en la creación de contenido para redes sociales, que es el objetivo central de esta investigación. La validez de estos supuestos es crucial para la relevancia y aplicabilidad de los resultados del estudio en el contexto más amplio de la adopción tecnológica en el ámbito de las redes sociales.

Capítulo II: Estado del Arte y Alcance

Estado actual del conocimiento

El estado del arte en el campo de la IA y la creación de contenido en redes sociales revela un creciente interés por parte de las personas en el potencial de la IA para apoyar los procesos cognitivos y creativos. La mayoría de las investigaciones proporcionan una visión general de la inteligencia artificial, donde se menciona desde definiciones, hasta capacidades y beneficios que conlleva el uso de la IA a través del aprendizaje automático, el análisis predictivo, análisis de Big Data, procesamiento del lenguaje natural, entre otros. El enfoque principal examina cómo las personas y la IA pueden aportar sus propias fortalezas para lograr una sinergia. (Davenport & Ronanki, 2018) (Franganillo, 2023) (Gómez-Diago, 2022) (García, Pinargote, Baque, & Montero, 2023) (González, Estévez, Jaramillo, & Flores, 2023)

Un ejemplo muy práctico es el que plantea (Nodd3r, 2022) y la plataforma de streaming Netflix, la cual ha revolucionado la experiencia de sus usuarios mediante el uso del aprendizaje



automático. Analizando minuciosamente el historial de visualización de cada usuario, Netflix emplea algoritmos de IA para ofrecer recomendaciones personalizadas de contenido. Inclusive, un ejemplo más claro de ello y de que estos algoritmos han marcado la diferencia en esta plataforma fue la primera serie que lanzó llamada House of Cards y que tuvo un gran éxito. Gracias al algoritmo Netflix estableció el género de la serie, el protagonista, el director, entre otros. Además, el algoritmo también les ayudó a ajustar las campañas de Marketing y publicidad. (Ramirez, 2018)

El Modelo Unificado de Aceptación y Uso de Tecnología 2 (UTAUT2) ha sido ampliamente aplicado en diversos sectores con el propósito de comprender los mecanismos de adopción tecnológica. El objetivo primordial de estas investigaciones es proporcionar una base sólida para el desarrollo de estrategias que fomenten una adopción efectiva y un uso óptimo de las nuevas tecnologías. Estas estrategias buscan no solo facilitar la integración de las innovaciones, sino también maximizar su potencial en beneficio de los usuarios finales.

Aunque el modelo UTAUT2 ha sido aplicado en una variedad de contextos, en esta sección nos enfocaremos específicamente en su aplicación para estudiar el uso de inteligencia artificial. Este enfoque nos permitirá examinar cómo los principios del modelo se manifiestan en un área que está experimentando una rápida transformación debido a la introducción de nuevas herramientas y plataformas tecnológicas.

Un reciente estudio de (Wang & Zhang, 2023) examinó la adopción de la inteligencia artificial generativa (GenAI) en el diseño entre la Generación Z en China. La investigación se basó en el modelo UTAUT2, incorporando además elementos del Índice de Preparación Tecnológica y el concepto de Curiosidad como rasgo personal. El análisis, que involucró a 326 participantes, reveló hallazgos interesantes sobre los factores que influyen en la intención de uso de GenAI. Se descubrió que aspectos como la facilidad de uso percibida, el valor económico y el placer asociado al uso de la tecnología tienen un impacto positivo en la adopción, sorprendentemente, la expectativa de rendimiento no mostró una influencia significativa.



El estudio también destacó la importancia de características personales como el optimismo y la creatividad, que mostraron correlaciones positivas con varios factores del modelo UTAUT2. Además, se identificó que la Curiosidad como rasgo juega un papel importante, influyendo tanto en el optimismo como en la intención de uso de GenAI. Los resultados de esta investigación sugieren la necesidad de refinar las estrategias de desarrollo y promoción de plataformas GenAI, con el fin de aumentar su atractivo y adopción entre los jóvenes de la Generación Z.

La investigación de (Emon, Hassan, Nahid, & Rattanawiboonsom, 2023) analizó la adopción de ChatGPT entre profesionales bangladesíes, utilizando el modelo UTAUT. El estudio examinó cómo factores como la actitud hacia la IA, las expectativas de rendimiento, la influencia social y la confianza afectan la intención y el uso real de esta tecnología. Los resultados destacan la importancia de reforzar las intenciones de uso, resaltar los beneficios y crear un entorno favorable para la adopción. El estudio ofrece resultados tanto teóricos como prácticos, útiles para organizaciones y responsables de políticas que buscan optimizar el uso de IA en contextos profesionales en Bangladesh.

La investigación de (Poonpanich & Buranasiri, 2022) se centra en analizar los factores que influyen en las actitudes de los baby boomers hacia la aceptación de chatbots de inteligencia artificial (IA) ofrecidos por proveedores de redes móviles en Tailandia. Los baby boomers son personas nacidas entre 1946 y 1964, un grupo que experimentó un notable crecimiento demográfico tras la Segunda Guerra Mundial. En este estudio, se encuestó a 400 individuos de esta generación que tienen experiencia en el uso de chatbots de IA. El marco teórico del estudio se basa en el Modelo de Aceptación Tecnológica (TAM), la Teoría Unificada de Aceptación y Uso de Tecnología 2 (UTAUT2) y la Teoría de Difusión de Innovaciones (IDT). Se utilizó un cuestionario para recopilar datos, y se aplicaron diversas técnicas estadísticas, como análisis factorial confirmatorio y modelos de ecuaciones estructurales.

Los resultados del estudio destacan la importancia de factores como la utilidad percibida, la facilidad de uso, la compatibilidad, la preocupación por la privacidad, la actitud



hacia la publicidad y la influencia social en la aceptación de la tecnología de chatbots de IA. Estos hallazgos resultan útiles para que las empresas desarrollen estrategias más efectivas para fomentar el uso de chatbots entre este grupo demográfico.

El estudio de (Chew, y otros, 2024) analizó la aceptación de aplicaciones de control de peso con IA entre adultos con sobrepeso y obesidad en el sudeste asiático. La investigación, que involucró a 271 participantes de una región desarrollada del sudeste asiático, utilizó el modelo UTAUT2 para analizar los factores que influyen en la aceptación de estas tecnologías. La investigación reveló que el 70% de los participantes estaban dispuestos a usar estas aplicaciones. El modelo explicó más del 60% de la varianza en la intención de uso, identificando las expectativas de rendimiento, la motivación hedónica y el hábito como los principales predictores. Los resultados sugieren que el UTAUT2 es útil para entender y guiar el desarrollo de aplicaciones de salud basadas en IA, especialmente en contextos multiculturales. A pesar de que existe una diferencia entre el tema de investigación principal, ambos temas se centran en la aplicación de inteligencia artificial para mejorar la experiencia del usuario.

Es importante notar que estas investigaciones pueden no estar directamente relacionadas con la creación de contenido en redes sociales utilizando IA. Es por esto por lo que esta investigación podría estar explorando un área relativamente nueva al aplicar UTAUT2 en este contexto particular.

Propuesta de valor

Al reconocer que el mundo está empezando a operar en un entorno digital en constante evolución, esta investigación busca aportar una perspectiva relevante y actualizada sobre cómo la IA puede adaptarse y ser un aliado en este contexto cambiante. La implementación de una investigación centrada en el uso de la inteligencia artificial para la creación de contenido en redes sociales representa una oportunidad significativa para explorar un área emergente y de gran relevancia. Al aplicar el modelo UTAUT2 en este contexto, la investigación puede ofrecer una serie de beneficios valiosos.



En primer lugar, esta investigación permitirá identificar y analizar los factores que influyen en la aceptación de herramientas de IA para la creación de contenido. Al aplicar UTAUT2, se podrán evaluar aspectos como la utilidad percibida, la facilidad de uso, la influencia social y la motivación hedónica, proporcionando así una visión integral de cómo los usuarios interactúan con estas tecnologías. Además, al comprender mejor las preferencias y actitudes de los usuarios se podrán desarrollar estrategias más efectivas y personalizadas.

La investigación también contribuirá a la innovación al explorar cómo la IA puede transformar la creación de contenido. Esto abrirá nuevas posibilidades para la automatización y personalización del contenido, mejorando su relevancia y resonancia con las audiencias objetivo. Asimismo, al investigar este fenómeno, las empresas y creadores tecnológicos podrán posicionarse a la vanguardia de la adopción tecnológica, permitiéndoles adaptarse rápidamente a las nuevas dinámicas del mercado y a las expectativas de los consumidores.

Finalmente, la aplicación de UTAUT2 en este contexto es un área relativamente nueva que puede enriquecer el cuerpo de conocimiento existente. Los hallazgos de esta investigación no solo serán valiosos para académicos y profesionales, sino que también podrán servir como base para futuras investigaciones y desarrollos en el campo.

Alcance de la memoria

Esta investigación tiene como propósito evaluar la aceptación de la inteligencia artificial en la creación de contenidos para redes sociales en Chile. Por lo tanto, dentro del alcance de esta investigación se busca entender cómo los usuarios incorporan estas herramientas en sus procesos creativos y qué factores influyen en su adopción. Para ello, se realizará una encuesta a una muestra representativa de jóvenes usuarios activos de redes sociales, analizando sus experiencias, percepciones y actitudes hacia la IA en la generación de contenido a través del modelo UTAUT2. Se explorarán aspectos como la motivación detrás del uso de la inteligencia artificial, la percepción de la calidad del contenido generado y la influencia de la interacción social en la aceptación de estas tecnologías.



Es importante destacar que el alcance de esta investigación está limitado al contexto de la inteligencia artificial aplicada a la creación de contenido en redes sociales. Sin embargo, los hallazgos y conclusiones obtenidos podrían ser de gran utilidad para otras áreas, como el marketing digital y la comunicación, donde la inteligencia artificial está desempeñando un papel cada vez más relevante. Además, servir como base para futuras investigaciones que busquen profundizar en la intersección entre tecnología y creatividad en el entorno digital.

Capítulo III: Marco Teórico

Web social

El término de web social se centra en la interacción entre usuarios de internet. Estos usuarios no se limitan únicamente a consumir medios en línea, en cambio, se convierten en productores de contenidos mismos, por lo tanto, el contenido generado por el usuario constituye una de las principales características (Fauser, Wiedenhofer, & Lorenz, 2011). Según (Ebersbach, Glaser, & Heigl, 2008) la web social consiste en aplicaciones basadas en la web (www) que ayudan a las personas a intercambiar información, establecer y mantener relaciones, comunicarse y colaborar en un contexto social y colectivo. Dentro de esta web social se pueden identificar cinco categorías de plataformas.

- **Wikis:** Plataformas online enfocadas en la creación de información de manera colaborativa, de forma que los usuarios rápida, sencilla e intuitivamente pueden crear, modificar, corregir o eliminar los contenidos compartidos. El ejemplo más conocido es Wikipedia.
- **Blogs:** Es un sitio web que a menudo es comparado con diarios, ya que son principalmente “diarios en línea” donde su autor o autores publican contenidos de su interés que suelen estar actualizados con frecuencia y a menudo son comentados por los lectores.
- **Microblogs:** Es una mezcla entre un Messenger, porque lo que se escribe se publica al instante, tienes una cantidad límite de caracteres y además puedes tener a un grupo de amigos a los que enviar mensajes privados o en grupo, y un blog, ya que tus mensajes quedan publicados y no se pierden cuando terminas la conversación.

- **Compartir social:** O también conocidos como Social sharing en inglés, son sitios web o aplicaciones que ofrecen la posibilidad de compartir e intercambiar contenido digital. Algunos ejemplos conocidos son Flickr, SoundCloud ó Pinterest.
- **Redes sociales:** Se utilizan principalmente para establecer y mantener relaciones y generalmente proporcionan a sus usuarios páginas de perfil que pueden adaptarse individualmente. Los ejemplos más conocidos son Facebook, Instagram, X, TikTok, entre otros.

(Ebersbach, Glaser, & Heigl, 2008) derivaron un esquema de clasificación que refleja el propósito principal de cada categoría desde la perspectiva del usuario, al tiempo que añade la colaboración como una cuarta funcionalidad de la web social.



Fig. 1. Esquema de clasificación de diferentes categorías de la Web Social.

Fuente: (Ebersbach, Glaser, & Heigl, 2008)

Redes sociales

De acuerdo con (Kaplan & Haenlein, 2010), las redes sociales son aplicaciones que permite a los usuarios conectarse entre sí, creando información personal como perfiles, invitando a amigos y colegas a tener acceso a dichos perfiles y enviar mensajes instantáneos entre sí. Estas plataformas permiten la creación y el intercambio de cualquier información o contenido generado por el usuario, incluyendo fotografías, vídeos, archivos de audio y blogs.



Una definición más reciente es la de (Carr & Hayes, 2015), donde ambos las describen como plataformas basadas en internet que facilitan la interacción social, la creación de contenido por parte de los usuarios y el intercambio de información entre usuarios dentro de una red dada.

Redes sociales en Latinoamérica

De acuerdo con (Statista Research Department, 2024) los datos de febrero de 2024 que pueden ser visualizados en la Figura 2 revelan que, en América Latina, Chile encabeza la lista de países con mayor penetración de redes sociales, con un 77,4% de su población como usuarios activos. Le sigue de cerca Antigua y Barbuda, donde el 77,2% de los habitantes utilizan regularmente estas plataformas de comunicación digital. Costa Rica también se destaca en este aspecto, completando el podio de naciones con mayor adopción de redes sociales en la región.

El auge de estas plataformas ha dado origen a un nuevo fenómeno profesional: los influencers. Estos individuos se caracterizan por su significativa presencia en el entorno digital y su habilidad para atraer y mantener una gran base de seguidores. Su relevancia ha crecido hasta el punto de convertirse en figuras clave en las estrategias de marketing de diversas empresas, actuando como promotores de marcas y productos.

En cuanto a la distribución de influencers en la región, Brasil y Argentina se posicionan a la vanguardia. Ambos países superan la marca de 10 millones de influencers en Instagram, lo que los sitúa como los mercados más importantes para este tipo de marketing digital en América Latina.




Fig. 2. Tasa de penetración de las redes sociales en América Latina y el Caribe en febrero de 2024, por país.

Fuente: (Statista Research Department, 2024)

“Chile está muy desarrollado en comparación con otros países que conozco de América Latina, y su economía estable le da ventajas. Además, esta generación está muy bien preparada a nivel de estudiantes, los que están muy abiertos a aprender cosas nuevas.” (Miladinov, 2019).

Situación en Chile

(Kemp, 2024) realiza un resumen de la investigación realizada para la plataforma DataReportal por parte de (We Are Social; Meltwater, 2024) que contiene todos los datos, perspectivas y tendencias más recientes que se necesitan para comprender cómo las personas en Chile usan los servicios digitales en 2024.

Tal como se mencionó anteriormente, a inicios del 2024, los usuarios de plataformas sociales en Chile representaban aproximadamente tres cuartos de la población total (77,4%). Sin embargo, es crucial tener en cuenta que esta cifra no necesariamente refleja individuos únicos, ya que una persona puede tener múltiples cuentas. Mientras que las estadísticas



proporcionadas por las herramientas de publicidad de las principales redes sociales revelaron que, para el mismo período, había alrededor de 13,75 millones de usuarios mayores de edad (+18 años) en Chile, esta cantidad constituía casi el 90% de la población adulta del país en ese momento. En términos más generales, el 85% de la base total de usuarios de Internet de Chile (independientemente de la edad) utilizó al menos una plataforma de redes sociales en enero de 2024.

La Figura 3 nos proporciona una visión detallada de los hábitos digitales de los chilenos, ofreciendo un panorama fascinante sobre las preferencias en línea de la población. En este análisis, se destaca de manera significativa que las redes sociales ocupan el primer lugar entre los sitios web y aplicaciones más frecuentados en el país, este dato no sorprende considerando la creciente importancia de las plataformas sociales en la vida cotidiana. Lo que resulta aún más revelador es el tiempo dedicado a estas plataformas: el chileno promedio invierte diariamente 3 horas y 22 minutos en el uso de redes sociales. Esta cifra es considerable y refleja el papel central que estas plataformas han adquirido en la rutina diaria de los usuarios. Profundizando en las motivaciones detrás de este uso intensivo, se identifican varias razones fundamentales (We Are Social; Meltwater, 2024).

En primer lugar, destaca el deseo de mantener vínculos sociales, las redes sociales se han convertido en una herramienta esencial para que los chilenos permanezcan en contacto con sus seres queridos, ya sean familiares o amigos. Otro motivo es la exploración de contenido diverso, los usuarios chilenos recurren a las redes sociales como una fuente primaria para descubrir y consumir una amplia gama de material, desde artículos informativos para mantenerse al día con las últimas noticias y acontecimientos, como también, videos de entretenimiento para el ocio. Las redes sociales cumplen una función de ocio significativa, muchos chilenos las utilizan como una forma de pasar su tiempo libre, ya sea scrolleando por sus feeds, interactuando con publicaciones o simplemente como una forma de distracción y entretenimiento. Esta versatilidad en el contenido disponible contribuye sin duda a la atracción y retención de usuarios en estas plataformas.




Fig. 3. Principales tipos de sitios web visitados y aplicaciones utilizadas

Fuente: (We Are Social; Meltwater, 2024)

Redes sociales más usadas en Chile

Al analizar detenidamente los patrones de uso y las preferencias de los usuarios chilenos en el ámbito de las redes sociales, nos encontramos con datos reveladores que merecen una exploración más profunda. La información recopilada en la Tabla 1 nos presenta un panorama fascinante del ecosistema digital en Chile.

En primer lugar, es notable que WhatsApp se posiciona como la plataforma con el mayor número de usuarios activos mensuales. Esta aplicación de mensajería instantánea se ha convertido en una herramienta indispensable para la comunicación diaria de los chilenos, tanto en el ámbito personal como profesional. Sin embargo, lo que realmente llama la atención es que a pesar de su amplia base de usuarios, WhatsApp no se corona como la red social favorita del país. Sorprendentemente, ese título lo ostenta Instagram, según los datos, aproximadamente un tercio de los encuestados (33,8% para ser exactos) eligieron esta plataforma visual como su red social favorita. Este fenómeno podría atribuirse a la naturaleza altamente visual y estética de Instagram, que permite a los usuarios compartir momentos de su vida a través de fotos y videos cortos, además de ofrecer una experiencia de navegación intuitiva y atractiva.



Otro dato que merece especial atención es el comportamiento de los usuarios en TikTok. Esta plataforma relativamente nueva en comparación con sus competidores ha logrado capturar la atención de los chilenos de una manera sin precedentes. Los datos indican que TikTok se destaca significativamente como la red social donde los usuarios invierten la mayor cantidad de tiempo, este fenómeno podría explicarse por el formato de video corto y el algoritmo altamente efectivo de TikTok, que mantiene a los usuarios enganchados con un flujo constante de contenido personalizado.

Es importante considerar que estas tendencias reflejan no solo las preferencias de los usuarios, sino también las estrategias de las plataformas para mantener a su audiencia comprometida, cada red social ofrece una experiencia única, y los chilenos parecen aprovechar diferentes plataformas para satisfacer distintas necesidades de comunicación y entretenimiento.

Ranking	Red social	Porcentaje de usuarios activos	Porcentaje de usuarios que dicen que es su app favorita	Horas mensuales que gastan los usuarios
1°	Whatsapp	93,8%	27,7%	16 horas
2°	Instagram	87,6%	33,8%	19 horas
3°	Facebook	85,6%	13,1%	15 horas
4°	Tik Tok	66%	13,1%	42 horas
5°	Facebook messenger	64,4%	0,9%	1 hora
6°	X (ex Twitter)	47,8%	2,9%	3 horas

Tabla 1. Redes sociales más usadas en Chile.

Fuente: *Elaborada en base a información recopilada de (We Are Social; Meltwater, 2024).*

Uso de redes sociales por edades en Chile

Un análisis detallado de la Tabla 2 revela patrones interesantes en el uso de las redes sociales pertenecientes al conglomerado Meta en Chile. Este grupo de plataformas incluye a WhatsApp, Facebook, Facebook Messenger e Instagram y muestra una distribución demográfica particular entre sus usuarios. Lo que más llama la atención es la predominancia de un grupo etario específico. Los datos indican que el segmento de población entre 25 y 34 años



se destaca como el más activo en estas plataformas seguido del segmento entre 18 a 24 años.

Estos grupos parecen tener una afinidad especial con las redes sociales, esta preferencia podría explicarse por varios factores. Por un lado, estos grupos crecieron junto con el auge de las redes sociales, adaptándose rápidamente a su uso. Por otro lado, se encuentran en una etapa de vida donde la conectividad social y profesional es crucial, lo que podría impulsar su participación en estas plataformas.

Además, el grupo etario entre 25 a 34 años es el único rango de edad donde se observa una mayor presencia masculina que femenina entre los usuarios. Este dato contrasta con la tendencia general, donde habitualmente se registra una participación femenina más alta.

Ranking	Edades	Hombres	Mujeres
1°	25 a 34 años	14,9%	14,3%
2°	18 a 24 años	9,5%	11,2%
3°	35 a 44 años	9,5%	10%
4°	45 a 54 años	6,3%	7,4%
5°	55 a 64 años	4,4%	5,7%
6°	Más de 65 años	2,9%	3,9%

Tabla 2. Ranking de edades con mayor cantidad de usuarios.

Fuente: *Elaborada en base a información recopilada de (We Are Social; Meltwater, 2024)*

Cómo nos referimos a la Inteligencia Artificial (IA)

La IA tiene varias definiciones, pero en términos generales, se refiere a sistemas inteligentes con la capacidad de pensar y aprender (Jarrahi, 2018). También se define como la capacidad de una entidad artificial para resolver problemas complicados utilizando su propia inteligencia (Mahto, 2023), o como la capacidad de las máquinas para usar algoritmos, aprender de los datos y utilizar lo aprendido en la toma de decisiones tal y como lo haría un ser humano (Rouhiainen, 2018).

Por lo tanto, la IA se basa en la idea de crear sistemas que puedan simular procesos cognitivos como el razonamiento, el aprendizaje automático, la percepción y la comprensión del lenguaje natural, para lograr que sean capaces de realizar acciones de manera autónoma, analizar el entorno, procesar grandes cantidades de información, realizar análisis predictivo y tomar decisiones profundas que ayuden a la efectividad de la toma de decisiones estratégicas y a la productividad.

Funcionamiento de la IA

Para entender cómo funciona una Inteligencia Artificial, es importante conocer ciertos subcampos que la conforman. La figura 4 presenta esquemáticamente las diferentes técnicas inteligentes y su correlación entre ellas.




Fig. 4. Ilustración de la interrelación de las diferentes técnicas de inteligencia computacional señaladas. *Fuente:* (Salehi & Burgueño, 2018)

El Machine Learning o Aprendizaje Automático (AA) es definido por (Samuel, 1959) como el campo de estudio que da a los computadores la capacidad de aprender sin ser programados de manera explícita, esto quiere decir que son capaces de aprender de forma autónoma a través del análisis de datos y de la identificación de patrones. Gracias al conocimiento que adquieren luego pueden realizar predicciones.



El Deep Learning o Aprendizaje Profundo (AP), el cual es un subconjunto del machine learning, es un nivel de aprendizaje más profundo en el que las máquinas intentan imitar al cerebro humano permitiendo que sean capaz de razonar y entender qué es aquello que se le quiere enseñar, sin tener que decírselo explícitamente.

La base del AA y AP son las Redes Neuronales Artificiales (RNA) las cuales fueron propuestas por primera vez por (Mcculloch & Pitts, 1943) como un modelo computacional sencillo de cómo podrían trabajar juntas las neuronas biológicas en los cerebros animales para realizar computaciones complejas usando lógica proposicional. En palabras más simples es “un esquema de computación distribuida inspirada en la estructura del sistema nervioso de los seres humanos” (Salas, 2004). Una RNA en AA o AP se diferencia en la cantidad de capas ocultas. Típicamente en una RNA convencional se puede encontrar una o más capas ocultas, pero en una RNA de AA o AP se puede tener cientos de capas ocultas, cada una con varias unidades de procesamiento distintas (neuronas). (Diaz-Ramirez, 2021)

Las redes neuronales convolucionales (CNN) son un tipo de red neuronal diseñada específicamente para procesar datos con una estructura de cuadrícula, como imágenes. Se destacan por su capacidad para detectar y extraer características relevantes de los datos de entrada. Las CNN utilizan capas de convolución que aplican filtros a los datos de entrada, lo que les permite identificar patrones y características importantes. Estos algoritmos toman las imágenes como entrada y en cada una detectan una serie de características con base en patrones y son capaces de diferenciar unas imágenes de otras (Centeno, y otros, 2023). Las CNN pueden usarse para analizar y comprender la estructura de las imágenes, lo que permite generar nuevas imágenes con características similares o realizar tareas como la transferencia de estilo.

Las redes generativas adversarias (GAN) son un tipo de redes convolucionales presentadas por primera vez en el año 2014, este enfoque innovador consiste en un método para la optimización entre dos redes neuronales que compiten entre sí: un generador y un discriminador, con el objetivo de conseguir generar nuevas instancias idealmente indistinguibles (Torre, 2023). El generador crea nuevos datos a partir de un repositorio (como



imágenes) intentando imitar un conjunto de datos real. El discriminador, por su parte, es quien recibe el dato e intenta distinguir si este es verdadero (de los datos reales) o falso (generados artificialmente) (Atenas, Sanhueza, & Valenzuela, 2012). A medida que estas dos redes compiten, ambas mejoran continuamente: el generador produce datos cada vez más realistas, mientras que el discriminador se vuelve más hábil en detectar falsificaciones.

El fundamento teórico general del que derivan permite su utilización para la generación de cualquier tipo de datos, habiéndose demostrado efectiva en campos diversos como la visión por computadora, la edición de imagen, el procesamiento del lenguaje natural, la generación de imagen a partir de texto, entre otros. (Torre, 2023)

Según (Salehi & Burgueño, 2018) es importante distinguir la inteligencia artificial (IA) de la ciencia de datos y el Big Data, donde existe una considerable superposición entre estos métodos. La minería o ciencia de datos es un campo interdisciplinario que utiliza algoritmos específicos para extraer patrones (modelos) que logren descubrir ideas valiosas, estructuras, relaciones y tendencias en un conjunto de datos almacenados (Santos, 2019).

El término "Big Data" se refiere al “conjunto de datos que, por su volumen, variedad y por la velocidad a la que necesitan ser procesados, supera las capacidades de los sistemas informáticos habituales” (RAE, 2022). El análisis de estos grandes volúmenes de datos tiene como finalidad el proporcionar información valiosa, y gracias a las capacidades de la IA es posible procesar, analizar y extraer información de una vasta cantidad de datos para derivar conocimiento de forma autónoma (Kaplan & Haenlein, 2019).

Para cumplir con su objetivo se debe tener en consideración las 7 V de la Big Data. (Laney, 2001) definió las tres propiedades principales de la Big Data: volumen, velocidad y variedad. A partir de esto, distintos investigadores han ido complementando con nuevas propiedades V.



- I. **Volumen:** Cantidad muy grande de datos que están disponibles y se almacenan con la finalidad de ser procesados.
- II. **Velocidad:** Rapidez con que los datos son creados, almacenados y procesados.
- III. **Variedad:** Multiplicidad de fuentes, tipos y formatos de los datos.
- IV. **Veracidad:** Confianza del dato o fiabilidad, la cual es determinada básicamente por el origen de la fuente y la calidad del dato.
- V. **Viabilidad:** Capacidad que tienen las organizaciones en generar un uso eficaz al gran volumen de datos que manejan.
- VI. **Visualización:** Modo en que los datos son presentados, con el objetivo de potenciar la capacidad de análisis, la identificación de patrones o correlaciones entre variables.
- VII. **Valor:** Está dado por su aplicabilidad en la decisión, los datos que no contribuyan a la toma de decisiones no tienen valor.

Principales Capacidades de la IA

La automatización hace referencia al uso de tecnología y sistemas para realizar tareas de forma autónoma, sin la necesidad de intervención humana. El objetivo principal de la automatización es aumentar la eficiencia, la precisión y la productividad, al mismo tiempo que se reduce el costo y el tiempo necesarios para completar un trabajo. La inteligencia artificial tiene el potencial de transformar significativamente la eficiencia y las precisiones gracias a su aprendizaje automático y el procesamiento del lenguaje natural, permitiendo la automatización de tareas rutinarias (García-Vera, Juca-Maldonado, & Torres-Gallegos, 2023). “La automatización de los procesos industriales constituye uno de los objetivos más importantes de las empresas en la siempre incesante tarea de la búsqueda de la competitividad en un entorno cambiante y agresivo” (Moreno, 2001).

El Procesamiento lenguaje natural (PLN) “consiste en la utilización de un lenguaje natural para comunicarnos con la computadora, debiendo ésta entender las oraciones que le sean proporcionadas” (Vásquez, Huerta, Quispe, & Huayna, 2009). Ésta se ocupa de analizar y

comprender el lenguaje humano, tanto en su forma escrita como oral, para que las máquinas puedan entender y responder a las interacciones humanas de manera efectiva.

Los LLM (por sus siglas en inglés Large Language Models) son un tipo de modelo de aprendizaje profundo entrenado en enormes cantidades de datos de texto para adquirir conocimientos y habilidades de procesamiento del lenguaje natural. De aquí surgen los populares ejemplos como ChatGPT de OpenAI o Gemini de Google los cuales son modelos increíblemente flexibles y accesibles al público capaces de realizar tareas como responder preguntas, resumir documentos, traducir idiomas y completar oraciones.

La visión por computadora o visión artificial es considerada una rama de la inteligencia artificial clásica. Es definida por (Sanchez, 2002) como “Ciencia que estudia la interpretación de imágenes mediante computadores digitales”. Esta incluye la serie de fases necesarias para dotar a las máquinas de la capacidad de percibir y comprender información visual de forma que se trata de imitar el proceso que realizan los seres humanos (Alonso & Jara, 2016). Esta tecnología permite extraer información significativa de imágenes digitales, videos y otros inputs visuales, y tomar decisiones o realizar acciones basadas en esa información.



Fig. 5. Etapas de un Sistema de visión por computadora

Fuente: (Alonso & Jara, 2016)



Otra capacidad relevante es el análisis predictivo, el cual utiliza algoritmos de IA para identificar patrones, tendencias y relaciones en grandes conjuntos de datos, y luego construye modelos analíticos que pueden utilizarse para predecir resultados o probabilidades de eventos futuros. De acuerdo con (Zúñiga, Poveda, & Mora, 2023) el análisis predictivo mediante la utilización de IA, busca analizar datos históricos y actuales con el fin de pronosticar eventos o comportamientos futuros, acciones que permitan incrementar las posibilidades de obtención de óptimos y mejores resultados, brindar sugerencias sobre la manera de aprovechamiento de oportunidades futuras o la mitigación de probables riesgos y mostrar consecuencias de cada decisión que pueda ser tomada.

Inteligencia artificial generativa (GenIA)

De acuerdo con las definiciones de (Corredera, 2023), la Inteligencia Artificial Generativa ha experimentado un auge significativo en 2023, aunque sus principios fundamentales no son completamente novedosos. Este término engloba un conjunto de técnicas y aplicaciones diseñadas para crear contenidos diversos, como textos, imágenes o software, que resultan prácticamente indistinguibles de aquellos producidos por humanos. El proceso de funcionamiento de estas tecnologías se basa en el aprendizaje de las características esenciales de los contenidos que deben generar. Para lograrlo se alimentan con una extensa base de ejemplos reales, generalmente mediante un proceso de aprendizaje no supervisado. Una vez entrenadas, estas aplicaciones son capaces de producir nuevos contenidos que comparten las propiedades aprendidas.

La interacción con estos sistemas se realiza típicamente a través de instrucciones proporcionadas por usuarios humanos. Estas instrucciones, conocidas como prompts, suelen estar formuladas en lenguaje natural, permitiendo una comunicación fluida entre el usuario y la inteligencia artificial para guiar el proceso de generación de contenido (Corredera, 2023).

La reciente aparición de sistemas de chat como ChatGPT y Gemini ha marcado un hito en la creación automatizada de contenidos. Estos sistemas han demostrado una capacidad



impresionante para generar respuestas coherentes y documentos completos en base a las solicitudes de los usuarios. Su habilidad para procesar y responder a una amplia gama de preguntas y tareas, dentro de los dominios en los que han sido entrenados, representa un avance significativo en la interacción entre humanos y máquinas. Esta tecnología está transformando rápidamente la forma en que accedemos y generamos información en diversos campos.

Pero las aplicaciones de Inteligencia Artificial Generativa no se limitan solamente a generar texto o voz y abarcan un amplio espectro de funcionalidades (Wang & Zhang, 2023). En el campo de la Visión y Arte Generativos, herramientas como DALL-E y MidJourney han demostrado la capacidad de crear imágenes originales adoptando estilos aprendidos. Estas tecnologías también pueden producir música creativa, como lo demuestran Jukebox de OpenAI y Music LM de Google. Además, son capaces de generar código de software, como es el caso de GitHubCopilot.

El alcance de la IA Generativa va aún más lejos, abarcando áreas como el desarrollo de fórmulas farmacéuticas, el diseño de escenarios, la elaboración de argumentos legales y la creación de estrategias industriales. Esto incluye aplicaciones en sectores como la robótica, los vehículos autónomos y la agricultura, entre otros. El potencial de estas tecnologías para acelerar la producción de contenido valioso es considerable, ya sea bajo la supervisión de un experto humano o de forma autónoma (Corredera, 2023).

Inteligencia Artificial y Redes Sociales

Las redes sociales han experimentado notables transformaciones impulsadas por los continuos avances tecnológicos. En este escenario, se observa un aumento constante en la implementación de diversas herramientas y/o funcionalidades con el objetivo de potenciar la interacción y enriquecer la experiencia del usuario. (Calva-Cabrera, León-Alberca, & Arpi-Fernández, 2024)



Según (Kaplan & Haenlein, 2020) el proceso de creación de contenido es un proceso multifacético que engloba una amplia gama de actividades y habilidades, incluyendo la producción y distribución de material digital diseñado específicamente para plataformas de redes sociales, con el objetivo de atraer, involucrar y retener a una audiencia definida.

La integración de tecnologías emergentes como la realidad aumentada, la inteligencia artificial y la producción de contenido generativo está expandiendo los límites de lo que se considera como creación de contenido para redes sociales (Smith & Jones, 2022). La IA ha provocado cambios profundos en el funcionamiento de las plataformas de interacción social, alterando la forma en que los seres humanos se conectan, interactúan y procesan información. Al automatizar tareas y personalizar contenidos, la IA se ha convertido en una herramienta de gran utilidad para optimizar la producción y el impacto de las estrategias de marketing digital (Sanz, 2023).

Una de las principales ventajas de la IA reside en su capacidad para personalizar el contenido a gran escala. Al analizar los datos de los usuarios, sus interacciones y sus preferencias, la IA puede generar publicaciones altamente relevantes, aumentando así el alcance y el engagement. Esta personalización no solo mejora la experiencia del usuario, sino que también permite segmentar la audiencia de manera más precisa, logrando también ser beneficioso para las empresas que busquen optimizar sus campañas publicitarias. También, la IA tiene la capacidad de automatizar tareas repetitivas como la generación de ideas, la redacción de textos, la creación de imágenes y la programación de publicaciones. Al permitir que la IA realice estas tareas se puede ahorrar tiempo y recursos, permitiendo centrarse en otras tareas más importantes.

La presencia de la inteligencia artificial se ha vuelto cada vez más notoria en la vida diaria y en diversos campos profesionales, especialmente en las plataformas de redes sociales. En este contexto, los creadores de contenido se enfrentan al desafío de mantener un equilibrio entre la rapidez para publicar, la responsabilidad de ofrecer información precisa y objetiva, y la publicación de contenido de calidad sin perder de vista las necesidades del usuario final.



Es crucial reconocer que la IA tiene sus limitaciones y no puede reemplazar completamente la creatividad humana. Por ello, es esencial que tanto los usuarios comunes como los profesionales del marketing y los creadores de contenido supervisen cuidadosamente el material generado por IA, deben estar preparados para realizar los ajustes necesarios, asegurándose de que el contenido automatizado se adapte adecuadamente a las expectativas y preferencias de ellos y de su audiencia.

Modelos y Teorías de aceptación de nueva tecnológica

El auge de los avances tecnológicos y la creciente adopción de nuevas tecnologías ha motivado a los investigadores a concentrarse en la creación de esquemas teóricos que buscan comprender cómo las personas interactúan con las innovaciones tecnológicas. Esta línea de investigación ha logrado encontrar aplicación en diversos campos por lo que es relevante el estudio de los modelos propuestos con el fin de encontrar el modelo que mejor pueda ajustarse a la investigación y ofrecer una explicación más precisa del fenómeno estudiado.

Teoría de acción razonada (TRA)

La TRA es un modelo ampliamente estudiado de la psicología social y desarrollado entre 1975 y 1980 por (Ajzen & Fishbein, 1975) (Ajzen & Fishbein, 1980), en el cual se plantea que la actitud de un individuo hacia una situación y la norma subjetiva se combinan entre sí para explicar el comportamiento real de una persona. La base del marco conceptual TRA está dada por la distinción entre creencias, normas, actitudes, intenciones y comportamientos de una persona al tomar una decisión y desde allí predice el comportamiento que puede resultar (Alomary & Woollard, 2015).

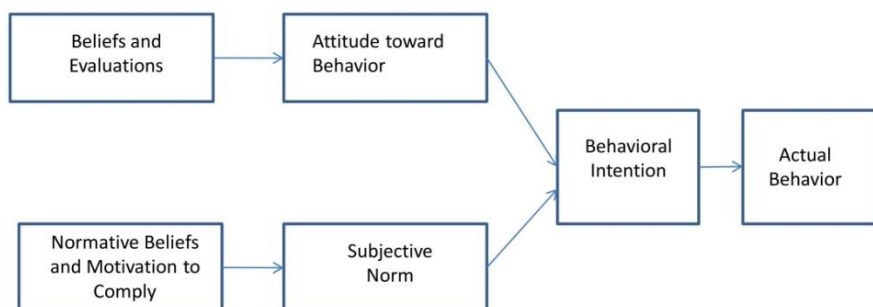


Fig. 6. Teoría de la Acción Razonada (TRA)

Fuente: (Ajzen & Fishbein, 1975) (Ajzen & Fishbein, 1980)

Modelo de aceptación de tecnologías (TAM)

(Davis, 1989) plantea el modelo TAM como una adaptación del modelo TRA, utilizándolo como base teórica para explicar la intención de uso de nuevas tecnologías. De esta manera el modelo TAM busca representar como los usuarios aceptan y utilizan una nueva herramienta tecnológica mediante el análisis de diversos factores.

Este modelo se basa en la idea de que el uso de las nuevas tecnologías está fuertemente relacionado con la intención de uso, la cual a su vez depende de la actitud del usuario hacia el uso de la tecnología. Por lo tanto, el modelo postula que esta actitud se compone en dos variables principales: la utilidad percibida y la facilidad de uso percibida. A continuación, se definen estas variables y los factores que afectan al modelo.

- I. **Utilidad Percibida (U):** Representa el grado en el que una persona estima que el uso de un determinado sistema mejoraría su desempeño.
- II. **Facilidad Percibida de Uso (E):** Refleja el grado en el cual una persona espera o cree que el sistema esté libre de esfuerzos en su uso.
- III. **Actitud Frente al Uso (A):** Sentimiento ya sea positivo o negativo que le genera el acto de realizar una conducta al sujeto.
- IV. **Intención de Uso (BI):** Es la probabilidad percibida de un sujeto o probabilidad subjetiva de que este se involucre o no en un comportamiento dado.

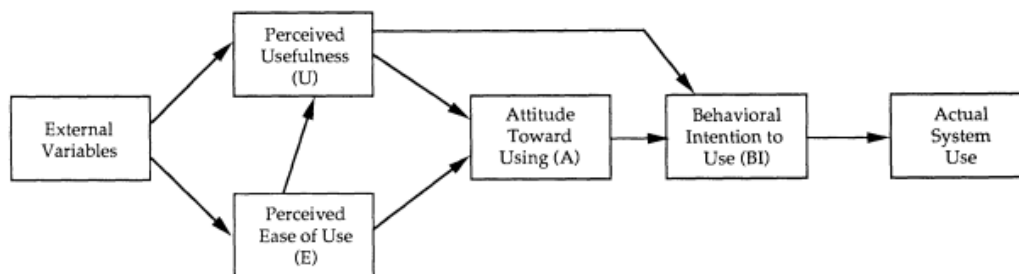


Fig. 7. Modelo de aceptación de tecnologías (TAM)

Fuente: (Davis, 1989)

Modelo de aceptación de tecnologías 2 (TAM2)

El modelo TAM2 planteado por (Venkatesh & Davis, 2000) es una extensión del modelo TAM que incorpora nuevas variables, la influencia social que incluye las normas subjetivas e imágenes y los procesos cognitivos donde se adhieren la relevancia laboral, la calidad de salida, demostrabilidad de resultados y la facilidad de uso percibida.

Entre las variables adicionales consideradas se encuentran:

- I. **La voluntariedad o percepción de libertad de elección:** Alude a cuán opcional o impuesta se percibe la adopción de una nueva herramienta tecnológica.
- II. **Experiencia del usuario:** Considera su familiaridad previa en relación con el uso de sistemas familiares.
- III. **La norma subjetiva:** Se refiere a cómo las opiniones de personas cercanas influyen en la decisión de adoptar o rechazar una nueva tecnología.
- IV. **La imagen:** Busca evaluar en qué medida se cree que el uso de un sistema particular mejora el estatus social del individuo.
- V. **La relevancia en el trabajo:** Evalúa cuán aplicable se percibe un sistema en el entorno de trabajo.
- VI. **La calidad de la salida:** Se refiere a la opinión o percepción sobre la calidad del desempeño del sistema en sus funciones asignadas.

VII. **La demostrabilidad de resultados:** Alude a la capacidad de demostrar de manera palpable y clara las ventajas y logros obtenidos al implementar la tecnología en cuestión.

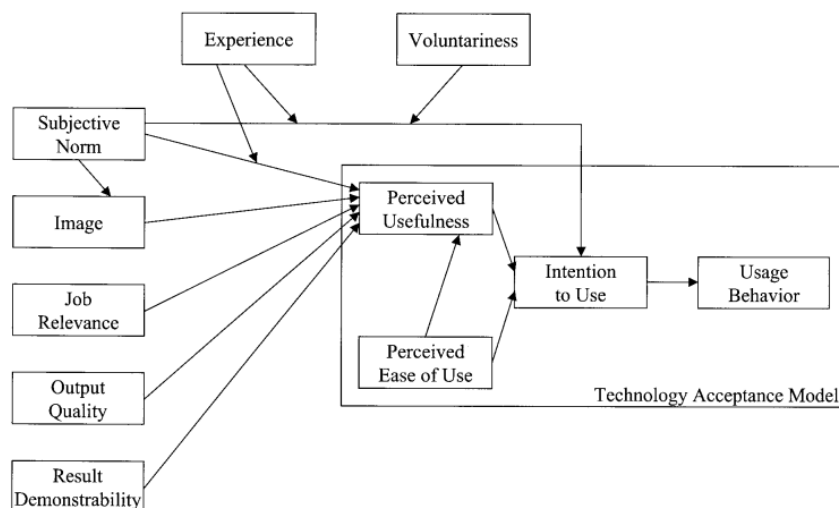


Fig. 8. Modelo de aceptación de tecnologías 2 (TAM2)

Fuente: (Venkatesh & Davis, 2000)

Teoría unificada de la aceptación y uso de la tecnología (UTAUT)

Dentro de las investigaciones que se llevaban a cabo para estudiar la adopción de tecnologías surge la necesidad de crear un modelo unificado que retomara los constructos que otras teorías y modelos habían comprobado que eran útiles en la evaluación de la aceptación de la tecnología. Dado que solo era posible escoger un solo modelo teórico de adopción, lo que ignoraba la contribución y ventajas de otros modelos alternativos, Venkatesh, Morris, Davis, & Davis se plantearon analizar los modelos existentes, tratando de encontrar uno que fuera la síntesis de todos los anteriores y que lograra superar las limitaciones de cada uno de ellos. (Cardador, 2015). En la Fig. 9 se muestran las ocho teorías y modelos que han abordado el tema a través del tiempo, así como los constructos propuestos por cada uno de ellos.

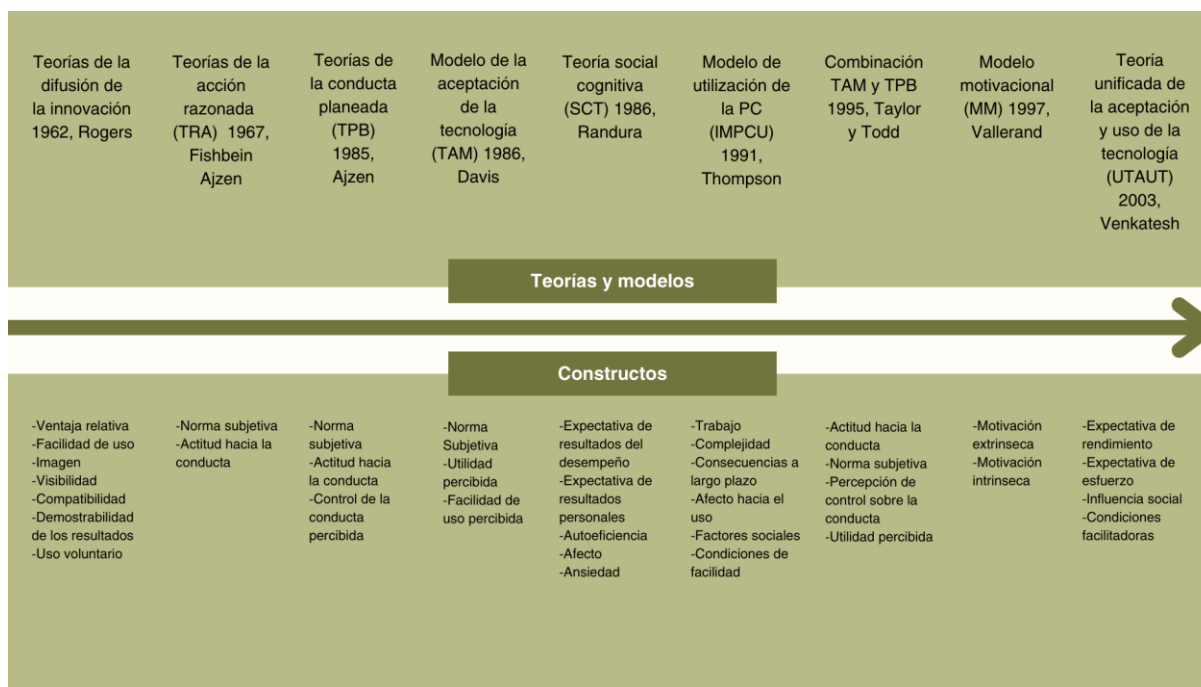


Fig. 9. Línea del tiempo de los modelos y teorías incluidos en la UTAUT.

Fuente: (Venkatesh, Morris, Davis, & Davis, 2003)

A través de este análisis, se construye un modelo denominado como Teoría unificada de la aceptación y uso de la tecnología (UTAUT) (Venkatesh, Morris, Davis, & Davis, 2003). De la totalidad de los constructos, se identificaron cuatro factores claves que predicen la intención de uso de las tecnologías, los cuales están moderados por variables moderadoras que son el género, la edad, la experiencia y la voluntad de uso; este último hace referencia a si el uso de la tecnología es voluntario o impuesto (Orellana, 2016):

- I. **Expectativa de rendimiento (ER):** Se refiere al grado en que un individuo cree que el uso del sistema o tecnología mejorará su desempeño.
- II. **Expectativa del esfuerzo (EE):** Hace referencia al grado de facilidad asociado al uso del sistema.
- III. **Influencia social (IS):** Se refiere al grado en que las personas, grupos o referentes importantes para un individuo influyen en su decisión de utilizar el sistema o tecnología.

IV. **Facilidad de condiciones (FC):** Representa el grado en que un individuo cree que la infraestructura organizacional y técnica es adecuada para apoyar y facilitar el uso del sistema.

Estas variables son moderadas por factores externos como lo es la Edad, el Género y la Experiencia del individuo. Además, en el modelo UTAUT, se establece que las variables de Expectativa del rendimiento, Expectativa del Esfuerzo e Influencia social tienen un impacto directo en la intención de uso, mientras que la variable de Facilidad de Condiciones tiene un impacto directo en la intención de uso y en el uso efectivo de la tecnología.

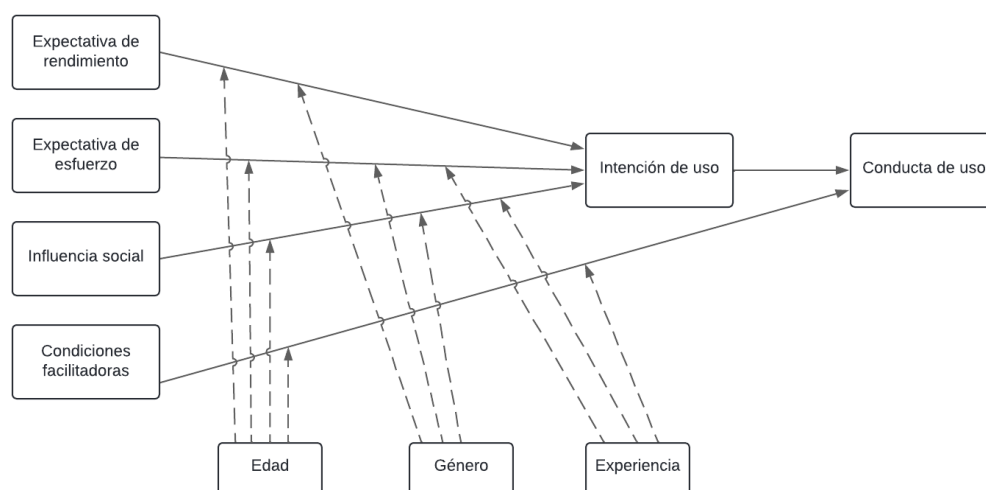


Fig. 10. Teoría Unificada de Aceptación y Uso de Tecnología (UTAUT).

Figura adapta de la Fuente: (Venkatesh, Morris, Davis, & Davis, 2003)

Teoría unificada de la aceptación y uso de la tecnología 2 (UTAUT2)

El modelo UTAUT2 (Venkatesh, Thong, & Xu, 2012) fue desarrollado específicamente con el objetivo de investigar la aceptación y uso de tecnologías en el entorno de consumidores y usuarios (dirigida a los consumidores en lugar de los empleados como en el caso del modelo UTAUT) añadiendo al modelo UTAUT original factores moderadores entre la variable de facilidad de condiciones (FC) y la intención de uso (IU) y tres nuevas variables, las cuales se ven moderadas por los mismos factores (edad, género y experiencia) para la intención de uso y la conducta de uso de la tecnología (Palos-Sanchez, Ana, & Saura, 2019):

- I. **Motivación Hedónica (MH):** Este factor hace referencia a la diversión, el disfrute o placer que obtiene un usuario al utilizar una tecnología. La motivación hedónica influye en la aceptación y uso de la tecnología en un contexto de consumo.
- II. **Valor – Precio (VP):** En el contexto de los consumidores, hace referencia a la relación de compromiso entre el beneficio percibido por el usuario al usar la tecnología y el precio que paga por ello. A diferencia de los demás, este factor sólo se encuentra moderado por la Edad y el Género del individuo.
- III. **Hábito (HT):** Este factor busca reflejar los resultados de las experiencias adquiridas anteriormente. Se define como la tendencia de los individuos a realizar comportamientos de manera automática debido al aprendizaje.

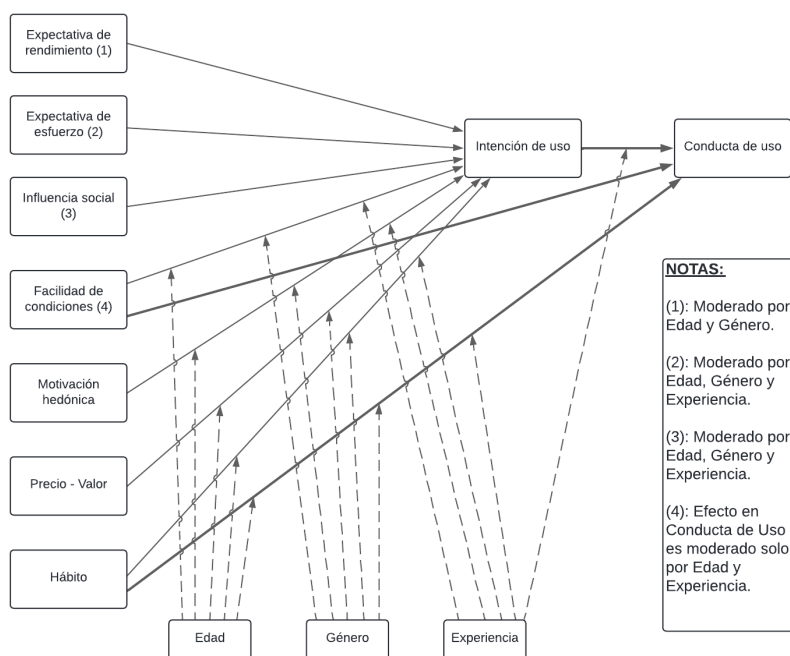


Fig. 11. Teoría Unificada de Aceptación y Uso de Tecnología 2 (UTAUT2).

Figura adapta de la Fuente: (Venkatesh, Thong, & Xu, 2012)

El modelo UTAUT 2 mantiene los constructos y definiciones de UTAUT, pero las adapta a un contexto de consumidores. UTAUT 2 plantea que la intención de uso de la tecnología depende de si la tecnología es percibida como útil, fácil de usar, sugerida por alguien



importante, que los recursos necesarios para usar la tecnología estén presentes, la tecnología sea divertida de usar, el valor-precio de la tecnología sea rentable y si el usuario tiene o no un hábito de uso de la tecnología.

Modelo de ecuaciones estructurales (SEM)

El modelo de ecuaciones estructurales es una metodología estadística que adopta un enfoque confirmatorio de factores (es decir, de prueba de hipótesis) para el análisis de una teoría estructural relacionada con algún fenómeno (Byrne, 2016). De acuerdo con lo mencionado, el objetivo principal es verificar cómo y en qué medida se relacionan las variables con sus factores subyacentes mediante análisis estadísticos y pruebas de hipótesis planteadas por el investigador.

El modelo SEM ha sido utilizado por investigadores durante años para probar las relaciones entre variables observadas y latentes, la razón más importante de la difusión de esta técnica estadística es que las relaciones directas e indirectas entre las variables causales se pueden medir con un solo modelo (Civelek, 2018), lo que permite estimar el efecto y las relaciones entre múltiples variables (Ruiz, Pardo, & Martín, 2010). Además, estas relaciones estructurales también pueden ser modeladas gráficamente para permitir una conceptualización más clara de la teoría en estudio. (Byrne, 2016)

Existen varios aspectos que le otorgan una ventaja y que distinguen al SEM de otros procedimientos multivariados (Byrne, 2016). Primeramente y como fue mencionado anteriormente, este modelo adopta un enfoque confirmatorio en lugar de exploratorio para el análisis de datos. En contraste, la mayoría de los otros procedimientos multivariados son esencialmente descriptivos por naturaleza lo que dificulta, si no imposibilita, la prueba de hipótesis. Segundo, mientras que los procedimientos multivariados tradicionales son incapaces de evaluar o corregir el error de medición, el SEM proporciona estimaciones explícitas de estos parámetros de varianza de error. Tercero, aunque los análisis de datos que utilizan los métodos anteriores se basan únicamente en mediciones observadas, los que utilizan procedimientos SEM



pueden incorporar variables no observadas (es decir, latentes) y observadas. Finalmente, no existen métodos alternativos ampliamente aplicados y fáciles de usar para modelar relaciones multivariadas, o para estimar efectos indirectos puntuales y/o por intervalos.

Variables observables y latentes

Las variables observables son aquellas que son medidas directamente ya sea por observación o de la recolección de datos, y que no han sufrido mayor manipulación matemática (Serrano, 2016). En cambio, las variables latentes o también conocidas como variables no observables, por lo general son el elemento de interés en el análisis y solo pueden ser observados a través de los efectos en las variables observadas ya que no pueden ser medidas de forma directa. Una sola variable observable no sería capaz de medir el efecto en una variable latente, es por esto por lo que se recomienda que el número de variables observadas conectadas a una latente sea como mínimo tres (Civelek, 2018).

Las variables latentes pueden ser divididas en dos categorías, endógenas y exógenas. Las variables latentes exógenas son aquellas que afectan a otras variables dentro del modelo, pero estas no se ven afectadas por ninguna, por lo tanto, son catalogadas como variables independientes y que sus fluctuaciones se deben solo a condiciones externas al modelo. En cambio, las variables latentes endógenas son aquellas que sufren variaciones a causa de otras variables del modelo, las fluctuaciones en los valores de estas variables están influenciadas por las variables exógenas del modelo, ya sea directa o indirectamente, por lo tanto, son catalogadas como variables dependientes.

Variables moderadoras y mediadoras

Una variable moderadora es un concepto utilizado para referirse a una variable cuantitativa o cualitativa que afecta la dirección o la fuerza de la relación entre una variable independiente y una variable dependiente. En otras palabras, la variable moderadora puede influir en cómo se manifiesta la relación entre estas dos variables, alterando su efecto (Garmendia, 2018).

En cambio, una variable mediadora se refiere a una variable que contribuye a explicar el mecanismo a través del cual una variable independiente influye en una variable dependiente. En otras palabras, la variable mediadora actúa como un intermediario en la relación entre estas dos variables, ayudando a entender cómo y por qué se produce dicha relación. (Garmendia, 2018)




Fig. 12. Efecto de moderación.

Figura de la Fuente: (Ato & Vallejo, 2011)




Fig. 13. Efecto de mediación.

Figura de la Fuente: (Ato & Vallejo, 2011)

Modelo general de ecuaciones estructurales

Los modelos de ecuaciones estructurales son representados esquemáticamente utilizando configuraciones particulares de cuatro figuras geométricas (Byrne, 2016):

- I. **Círculo o elipse (○):** Representan los factores o variables latentes (no observables).
- II. **Cuadrado o rectángulo (□):** Representan los factores o variables observables.
- III. **Flecha de una sola punta (→):** Representan el impacto de una variable sobre otra.
- IV. **Flecha de doble punta (↔):** Representan covarianzas o correlaciones entre pares de variables, normalmente son vectores curvos.

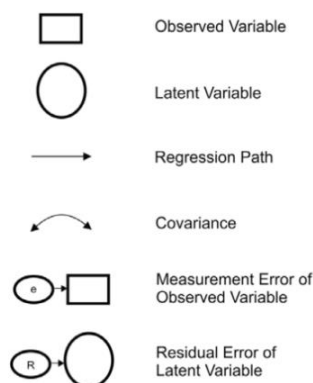


Fig. 14. Símbolos de una SEM

Figura de la Fuente: (Civelek, 2018)

Diagrama de senderos

Los esquemas gráficos que ilustran estos modelos se denominan diagramas de senderos ya que ofrecen una visualización de los vínculos hipotéticos entre las variables analizadas. Estos diagramas, al representar un modelo específico de ecuaciones estructurales, funcionan como el equivalente visual de su formulación matemática. En esencia, constituyen un conjunto de relaciones que vinculan las variables dependientes con aquellas que las explican, expresadas de manera gráfica.

El modelo general de SEM puede descomponerse en dos submodelos: un modelo de medición y un modelo estructural (Byrne, 2016) (Cupani, 2012).

- I. **Modelo de medición:** Define las relaciones entre las variables observadas y no observadas. En otras palabras, proporciona el vínculo entre las puntuaciones en un instrumento de medición (es decir, las variables observables) y los constructos subyacentes que están diseñados para medir (es decir, las variables latentes no observadas). El modelo de medición, entonces, representa el modelo de Análisis Factorial Confirmatorio (AFC o CFA en inglés) descrito anteriormente, ya que especifica el patrón mediante el cual cada medida carga en un factor particular.

- II. **Modelo estructural:** Define las relaciones entre las variables latentes o no observadas. En consecuencia, especifica la manera en que determinadas variables latentes influyen directa o indirectamente (es decir, "causan") cambios en los valores de ciertas otras variables latentes en el modelo.

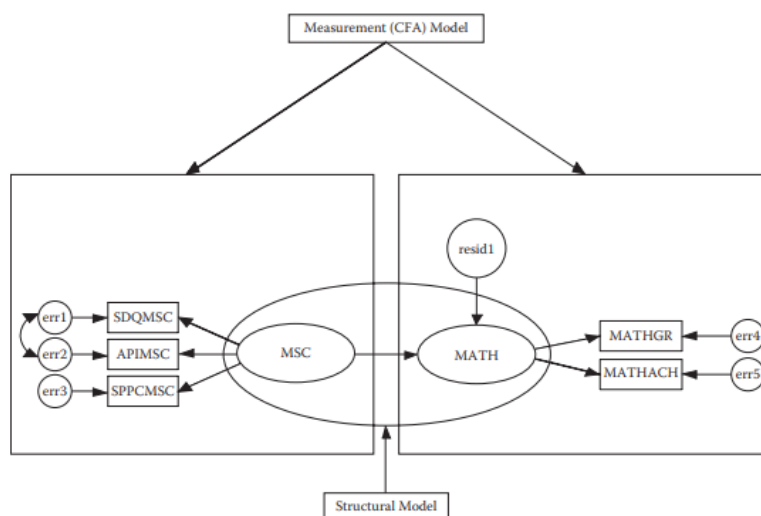


Fig. 15. Modelo general de SEM delimitado en componentes de medición y estructurales
 Figura de la Fuente: (Byrne, 2016)

Pasos para la modelación de ecuaciones estructurales

Los principales pasos por considerar al momento de modelar un SEM de acuerdo con los principales especialistas (Kaplan D. , 2000) (Kline R. B., 2005) (Byrne, 2016) son:

I. Conceptualización del modelo

Proceso donde se define y se diseña de manera conceptual las relaciones entre las variables planteadas en el modelo. Se debe determinar cuáles son las variables independientes, dependientes y mediadoras/moderadoras para luego definir cómo se relacionan estas variables entre sí.



II. Construcción del diagrama

Se debe plasmar el diagrama de senderos para representar visualmente las relaciones de causalidad o correlación entre las variables del modelo. Esta representación gráfica permite una mejor interpretación y entendimiento de las interconexiones entre las variables, ofreciendo una ilustración visual del marco conceptual propuesto.

III. Especificación del modelo

En esta fase se busca establecer formalmente el modelo, fundamentando teóricamente las relaciones entre variables latentes y observables. Este proceso implica la definición explícita de relaciones entre variables, asumiendo que aquellas no especificadas son nulas. El investigador aplica sus conocimientos sobre la materia para así formular las relaciones matemáticas, los supuestos y los parámetros que conformarán las bases de la investigación. Es de suma importancia contar con un sólido conocimiento teórico ya que la claridad y precisión del modelo están directamente relacionadas con el nivel de conocimiento teórico del investigador sobre el tema de estudio, además de evitar la necesidad de realizar modificaciones forzadas en etapas posteriores del proceso.

IV. Identificación del modelo

Una vez que se determina que el modelo teórico es correcto se procede a la identificación del modelo refiriéndose a la capacidad de estimar de manera única los parámetros del modelo a partir de los datos disponibles. El modelo está identificado si todos los parámetros lo están, es decir, si existe una solución única para cada uno de los parámetros estimados. Se examina si existe suficiente información en los datos para estimar correctamente los parámetros, un modelo es considerado identificado si hay suficientes datos para estimar todos los parámetros sin ambigüedad que dificulte la estimación precisa.

Una regla fundamental para determinar la identificación es la de los grados de libertad (g.l.). Se busca que los g.l. sean mayores o iguales a cero, clasificando los modelos en identificados (g.l. = 0) o sobre identificados (g.l. > 0). El objetivo es lograr un modelo sobre identificado, que permite una generalización más amplia de los resultados (Cupani, 2012).



V. Evaluación de la calidad de la base de datos

Antes del análisis en modelos SEM, es crucial examinar la calidad de la base de datos. El tamaño de la muestra es un tema controvertido: (Kline R. B., 2005) sugiere 10-20 participantes por parámetro estimado, (Hinkin, 1995) sugiere de 1 a 10 respuestas por ítem de la encuesta a realizarse, mientras que (MacCallum, Browne, & Sugawara, 1996) consideran que depende del poder estadístico deseado, las hipótesis y la complejidad del modelo. Y (Jackson, 2003) recomienda un mínimo de 200 sujetos para cualquier SEM.

La confiabilidad o fiabilidad, se refiere a la consistencia o estabilidad de una medida, con la creación del Alfa de Cronbach, los investigadores fueron capaces de evaluar la confiabilidad o consistencia interna de un instrumento constituido por una escala Likert, o cualquier escala de opciones múltiples (Virla, 2010). Por lo tanto, la prueba de fiabilidad está orientado para determinar si los datos recolectados son consistentes, para ello se aplica el Alfa de Cronbach, cuyos valores de acuerdo con (George & Mallery, 2003) son de confiabilidad aceptable si tienen un valor sobre 0.7.

La multicolinealidad entre variables debe evaluarse, cuando se observa que dos variables están altamente correlacionadas, la solución más práctica es retirar una de ellas del modelo. Entre 0 y 0.2 representan una correlación débil, entre 0.2 y 0.5 una correlación moderada, entre 0.5 y 0.8 una correlación buena y, entre 0.8 y 1 una correlación perfecta (Roy-García, Rivas-Ruiz, Pérez-Rodríguez, & Palacios-Cruz, 2019). Pero (Shrestha, 2020) indica que si el valor absoluto del coeficiente de correlación de Pearson está cerca de 0.8, es probable que exista colinealidad. Mientras que (Kline R. B., 2011) propone la existencia de multicolinealidad para correlaciones mayores de 0.95 y (Hair, Black, Babin, & Anderson, 2010) proponen que las correlaciones entre las variables deben ser menores a 0.90, por lo tanto y a modo de equilibrio, se buscarán valores menores a 0.9 para las correlaciones entre variables para evitar la multicolinealidad.



VI. Estimación de parámetros

La fase de estimación en los modelos de ecuaciones estructurales (SEM) implica determinar los valores de los parámetros desconocidos y sus errores de medición. Los investigadores utilizan programas especializados para este propósito.

El método de máxima verosimilitud (MV) es ampliamente utilizado por su eficiencia y ausencia de sesgo cuando se cumple el supuesto de normalidad multivariada. Sin embargo, debido a la sensibilidad de MV a la no normalidad, se han desarrollado técnicas alternativas como mínimos cuadrados ponderados (WLS), mínimos cuadrados generalizados (GLS) y asintóticamente libre de distribución (AGL). El método AGL ha ganado atención por su insensibilidad a la no normalidad de los datos, aunque requiere muestras considerablemente grandes ($N=500$ o más) para su aplicación efectiva (Cupani, 2012). La elección del método de estimación depende, por tanto, de las características de los datos y del tamaño de la muestra disponible.

VII. Evaluación del ajuste del modelo

La etapa de diagnóstico de la bondad del ajuste se refiere a la exactitud de los supuestos del modelo especificado para determinar si el modelo es correcto y sirve como aproximación al fenómeno real, precisando así su poder de predicción (Cupani, 2012). Las medidas de calidad del ajuste pueden ser de tres tipos:

- **Ajuste absoluto:** Establece el grado de ajuste global del modelo y determinar qué tan bien dicho modelo a priori se ajusta a los datos de la muestra (McDonald & Ho, 2002). Entre los principales índices se encuentran:
 - **Chi-cuadrado o Estadístico χ^2 :** El estadístico Chi-cuadrado es la única medida de bondad de ajuste en modelos de ecuaciones estructurales (SEM) asociada a un test de significación. La hipótesis nula plantea que el modelo predice la matriz de covarianzas observadas, buscando no rechazarla. Un buen ajuste requiere una probabilidad p menor



a 0,05. Sin embargo, esta medida presenta limitaciones: Es sensible al tamaño de la muestra: en muestras grandes (>200) tiende a rechazar modelos con pequeñas discrepancias, mientras que en muestras pequeñas puede aceptar modelos mal ajustados. En modelos complejos, aumenta la probabilidad de aceptación, llegando al ajuste perfecto en modelos saturados. Es muy sensible a violaciones del supuesto de normalidad multivariable.

- **Error cuadrático medio de aproximación (RMSEA):** Es una medida que proporciona una estimación de la calidad del ajuste que se esperaría si el modelo fuera aplicado a toda la población, en lugar de solo a la muestra utilizada en la estimación (Browne & Cudeck, 1993). Esta escala se ve afectada negativamente por el tamaño de la muestra. Un valor de 0.05 o menos para el índice de ajuste RMSEA indica un buen ajuste y valores entre 0.05 y 0.08 indican un ajuste aceptable (Civelek, 2018).
 - **Índice bondad ajuste (GFI):** Es una medida del grado de varianza y covarianza que es explicado por el modelo (Civelek, 2018). El valor del índice GFI aumenta a medida que el tamaño de la muestra se incrementa, esta característica puede impedir resultados precisos cuando el tamaño de la muestra es pequeño. El valor del GFI oscila entre 0 (ajuste deficiente) y 1 (ajuste perfecto). Valores superiores a 0.90 se consideran índices de modelo satisfactorios y valores de 0.95 o superiores, un ajuste óptimo (Cupani, 2012).
- **Ajuste incremental:** Se basan en la comparación entre el modelo propuesto con otro modelo base más restrictivo. Comúnmente se toma como modelo base un modelo saturado (todas sus variables están correlacionadas) o modelo independiente (no existe correlación entre sus variables).
- **Índice de ajuste normado (NFI):** Este estadístico evalúa comparando la variación proporcional cuando se pasa desde un modelo propuesto a uno nulo (Bentler & Bonett, 1980), el modelo nulo es el peor escenario, ya que especifica que todas las variables medidas no están correlacionadas (Hooper, Coughlan, & Mullen, 2008). Toma valores entre 0 y 1. Valores más altos indican un mejor ajuste, valores superiores a 0.90 son



- aceptables, mientras que valores superiores a 0.95 indican un buen ajuste (Civelek, 2018).
- **Índice de ajuste comparativo (CFI):** Compara la variación entre la matriz de covarianza del modelo propuesto con la matriz de covarianza del modelo nulo (Bentler & Bonett, 1980). Los valores del CFI pueden variar de 0 a 1; valores superiores a 0,90 y cercanos a 1 indican un buen ajuste (Schermelleh-Engel, Moosbrugger, & Müller, 2003).
 - **Índice de Tucker Lewis (TLI) o Índice de ajuste no normado (NNFI):** Este estadístico es una corrección al NFI, ya que considera los grados de libertad del modelo propuesto y el nulo y además no se ve muy influenciado por el tamaño de la muestra. Sus valores oscilan entre 0 y 1 siendo mejor el ajuste mientras mayor sea el valor, valores por sobre 0.9 son considerados aceptables. (Byrne, 2016)
- **Ajuste de parsimonia:** Los índices de ajuste de parsimonia evalúan la relación entre la calidad del ajuste del modelo y la cantidad de parámetros estimados. Su propósito principal es determinar si el ajuste logrado se debe a una excesiva complejidad del modelo, es decir, a un número elevado de coeficientes. Estos índices buscan valorar la simplicidad del modelo, promoviendo el uso de la menor cantidad posible de parámetros para explicar los datos.
- **Índice de ajuste normado de Parsimonia (PNFI):** Es una variante mejorada del índice de ajuste normado (NFI). Este indicador toma en cuenta la cantidad de grados de libertad empleados para alcanzar un determinado nivel de ajuste. Su cálculo implica ajustar el NFI mediante la razón entre los grados de libertad del modelo propuesto y los de un modelo nulo. Los expertos en el campo sugieren que un valor aceptable para el PNFI debe superar el 0.5.
 - **Criterio de información de Akaike (AIC):** Este índice resulta particularmente valioso cuando se necesita comparar modelos que difieren en el número de variables latentes que incorporan. El objetivo de este indicador es obtener el valor más bajo posible, ya que una puntuación menor sugiere un ajuste superior y una mayor parsimonia en el



modelo. Es importante destacar que este índice tiene limitaciones en su aplicabilidad, su uso se restringe a situaciones donde se emplea el método de estimación de máxima verosimilitud y se requiere que el tamaño de la muestra sea considerable, específicamente superior a 200 casos.

Los expertos en el campo sugieren la utilización de diversos indicadores para realizar una evaluación completa del ajuste del modelo. Es por esto por lo que (Cupani, 2012) hace referencia a los índices más frecuentemente utilizados en la práctica, donde destaca los siguientes: el estadístico chi-cuadrado, la razón de chi-cuadrado sobre los grados de libertad (CMIN/DF), el cambio en chi-cuadrado entre los modelos alternativos, el índice de ajuste comparativo (CFI), el índice de bondad de ajuste (GFI), y el error cuadrático medio de aproximación (RMSEA).

VIII. Re-especificación del modelo

Es poco común que el modelo inicialmente propuesto presente el mejor ajuste posible. Por esta razón, el investigador debe explorar estrategias para optimizar el ajuste del modelo. Este proceso implica modificar el modelo original, lo que puede incluir la eliminación o adición de variables, sean estas observables o latentes. Este procedimiento se conoce como re-especificación o modificaciones del modelo.

Sin embargo, es crucial enfatizar que cualquier modificación realizada debe estar fundamentada en una base teórica sólida, más allá de la mera búsqueda de resultados empíricos favorables. La re-especificación no debe ser un ejercicio arbitrario de ajuste de datos, sino un proceso reflexivo basado en el conocimiento teórico del fenómeno estudiado. Para realizar modificaciones se recomienda revisar dos indicadores:

- **Residuo estandarizado:** Los residuos estandarizados corresponden a la diferencia entre las matrices de covarianza o correlación observada y la matriz de covarianza o correlación estimada del modelo. Los valores residuales mayores que 2.58 se



consideran estadísticamente significativos a nivel de 0,05. Los residuos significativos indican un error de predicción sustancial para un par de indicadores (Cupani, 2012).

- **Índice de modificación:** Proporciona una estimación de la reducción potencial en el estadístico Chi-cuadrado si se incluyera un coeficiente específico en el modelo. Este valor indica aproximadamente cuánto podría disminuir el Chi-cuadrado al estimar dicho coeficiente. La magnitud del índice de modificación es relevante para la toma de decisiones en la re-especificación del modelo, Concretamente, cuando este índice alcanza o supera el valor de 3.84, sugiere que la inclusión del coeficiente en cuestión podría resultar en una disminución estadísticamente significativa del Chi-cuadrado. (Hair, Anderson, Tatham, & Black, 2004)

IX. Interpretación de los resultados

En la interpretación de los resultados de modelos de ecuaciones estructurales, se pueden adoptar dos enfoques distintos, cuya elección dependerá del objetivo principal del estudio según señala (Byrne, 2016).

El primer enfoque se centra en el análisis de coeficientes estandarizados. Esta aproximación permite comparar la relevancia relativa de las diferentes variables dentro del modelo. Una ventaja clave de estos coeficientes es que no se ven influenciados por las diferencias en las escalas de medición de las variables, lo que facilita la evaluación del impacto de cada variable en las relaciones causales del modelo. En este contexto, un coeficiente estandarizado de mayor magnitud sugiere una mayor importancia de esa variable específica en la estructura causal del modelo.

El segundo enfoque implica el análisis de coeficientes no estandarizados, los cuales se fundamentan en los principios de la regresión múltiple. Estos coeficientes son particularmente útiles cuando se busca examinar cómo se comporta un coeficiente de estimación específico al aplicar el modelo a diferentes muestras. Este método permite evaluar la robustez y consistencia



del coeficiente a través de diversos subgrupos de datos, proporcionando información sobre la estabilidad del modelo en diferentes contextos o poblaciones.

Capítulo IV: Propuesta de metodología

Entendiendo que se trata de un contexto de consumo se procedió a realizar una revisión bibliográfica en búsqueda de modelos de aceptación de tecnologías más adecuado para predecir el contexto en estudio. Durante la revisión se determina que el modelo que mejor se adapta a este contexto y con el mayor poder explicativo en cuanto a conductas y tecnologías es el modelo UTAUT 2, una extensión del modelo UTAUT el cual engloba teorías y modelos de otros investigadores, pero en un contexto de consumo.

Al utilizar el modelo UTAUT 2, se considerarán las 7 variables clave: expectativas de rendimiento, expectativa de esfuerzo, influencia social, facilidad de condiciones, motivación hedónica, valor-precio y hábito. Además de los moderadores: Edad, Género y Experiencia. Estos constructos proporcionarán una base sólida para analizar la actitud y el comportamiento de las personas que utilizan estas tecnologías para la creación de contenido en redes sociales.

Hipótesis

A continuación, se explicará cada una de las variables que están presente en el modelo UTAUT 2 y se propondrán las hipótesis para analizar y comprobar cómo las variables están relacionadas entre sí y cómo esa relación se refleja en el mundo real.

Expectativa de rendimiento (ER): Se define como el grado en que el uso de la tecnología proporcionará beneficios o mejorará el desempeño al consumidor (Venkatesh, Thong, & Xu, 2012). Por lo que, los consumidores parecen tener una mayor motivación a usar nuevas tecnologías si perciben que estas son más útiles en su vida diaria (Payam Hanafizadeh, 2014) (Chen, 2014) (Alalwan, Dwivedi, Rana, & Williams, 2016).



Esta variable es considerada como “el predictor que más influye en la intención de usar tecnología” (Cardador, 2015) y es moderada por el Género y la Edad del individuo (Venkatesh, Morris, Davis, & Davis, 2003), por lo que se propondrán las siguientes hipótesis:

H1: La Expectativa del rendimiento (ER) influye en la Intención de uso (IU)

H2: La Edad y el Género del individuo moderan la influencia de la Expectativa del rendimiento (ER) en la Intención de uso (IU)

Expectativa del esfuerzo (EE): Hace referencia al grado de facilidad asociado al uso del sistema, esta variable puede tener un efecto proporcional con la expectativa de rendimiento (ER), si los usuarios creen que una tecnología determinada es útil, pueden, al mismo tiempo, creer que el sistema es demasiado difícil de usar y que los beneficios de rendimiento del uso son superados por el esfuerzo de utilizar la aplicación (Davis, 1989).

De acuerdo con distintas investigaciones, se cree que cuanto menor sea la percepción de esfuerzo requerido para el uso de la tecnología, mayor será la intención de uso por parte del usuario. (F. Muñoz-Leiva, 2017) (Ngampornchai & Adams, 2016) (Lu, Yao, & Yu, 2005) y confirman que la facilidad de uso percibida, al igual que la utilidad percibida, son factores fundamentales para la intención de uso de las tecnologías por lo que se espera ver un impacto significativo de estos constructos.

Esta variable es moderada por el Género, la Edad y la Experiencia del individuo. (Venkatesh, Morris, Davis, & Davis, 2003), por lo que se propondrán las siguientes hipótesis:

H3: La Expectativa del esfuerzo (EE) influye en la Intención de uso (IU)

H4: La Edad, el Género y la Experiencia del individuo moderan la influencia de la Expectativa del esfuerzo (EE) en la Intención de uso (IU)

Influencia social (IS): Se refiere al grado en que las personas, grupos o referentes importantes para un individuo influyen en su decisión de utilizar el sistema o tecnología o para este contexto



también puede ser considerado como “las presiones percibidas de las redes sociales para tomar o no tomar una cierta decisión de comportamiento.” (Lu, Yao, & Yu, 2005)

La opinión y apoyo de personas influyentes y que rodean al individuo tienen un impacto significativo en la acción que este decide tomar, ya que los individuos adaptan sus actitudes, comportamientos y creencias a su contexto social. (Salancik & Pfeffer, 1978). Un usuario tenderá a adoptar una tecnología si percibe que las personas que tienen influencia sobre él suelen utilizarla o piensan que él también debe usar dicha tecnología, por lo que, la opinión y el apoyo social tienen un impacto significativo en la aceptación y adopción de la tecnología. (Il Im, 2011) (El-Masri & Tarhini, 2017)

Esta variable se encuentra moderada por el Género, la Edad y la Experiencia del individuo. (Venkatesh, Morris, Davis, & Davis, 2003), por lo que se propondrán las siguientes hipótesis:

H5: La Influencia social (IS) influye en la Intención de uso (IU)

H6: La Edad, el Género y la Experiencia del individuo moderan la Influencia social (IS) en la Intención de uso (IU)

Facilidad de condiciones (FC): Representa el grado en que un individuo cree que la infraestructura organizacional y técnica es adecuada para apoyar y facilitar el uso del sistema. (Venkatesh, Morris, Davis, & Davis, 2003) Se reporta frecuentemente que las condiciones facilitadoras influyen positivamente en la intención de uso y el uso efectivo de la tecnología. (Díaz, 2022) (Alghamdi AM, 2022) (Chawla & Joshi, 2019) En el contexto del consumo, el uso de Inteligencia Artificial para la creación de contenido en redes sociales requiere de ciertos elementos tecnológicos como lo son computadores, celulares o tablets, además de servicios como acceso a internet en algunos casos. También los conocimientos y habilidades pueden ser considerados como factores que hacen más fácil la adopción y uso de tecnologías.



Esta variable se encuentra moderada por la Edad, Género y la Experiencia del individuo dependiendo si es hacia la intención de uso (IU) o la conducta de uso (USO) (Venkatesh, Thong, & Xu, 2012), por lo tanto, se propondrán las siguientes hipótesis:

H7: La Facilidad de condiciones (FC) influye en la Intención de uso (IU)

H8: La Facilidad de condiciones (FC) influye en la Conducta de uso (USO)

H9: La Edad, el Género y la Experiencia del individuo moderan la influencia de la Facilidad de condiciones (FC) en la Intención de uso (IU)

H10: La Edad y la Experiencia del individuo moderan la influencia de la Facilidad de condiciones (FC) en la Conducta de uso (USO)

Motivación Hedónica (MH): Este factor hace referencia a la diversión, el disfrute o placer que obtiene un usuario al utilizar una tecnología. Debido al auge en los últimos años, el uso de inteligencia artificial se ha convertido en una tecnología novedosa. Tal innovación y búsqueda de novedad de parte de los usuarios pueden aumentar la motivación hedónica para usar cualquier producto (Holbrook & Hirschman, 1982).

Los individuos están más inclinados a aceptar nuevas tecnologías y alcanzar sus metas personales o profesionales si estas proporcionan placer o alegría. (Al-Adwan & Al-Debei, 2024), si el disfrute del individuo aumenta durante la utilización de estas nuevas tecnologías, se verá sumergido en ese momento influyendo en la intención de comportamiento de usarla continuamente. (Lowry, Gaskin, Twyman, Hammer, & and Roberts, 2013) (Kim & Hall, 2019) (Brown, Venkatesh, & Bala, 2006) Por lo tanto, es posible deducir que la motivación hedónica influye en la aceptación y la intención de uso de nuevas tecnologías.

Esta variable es moderada por el Género, la Edad y Experiencia del individuo (Venkatesh, Thong, & Xu, 2012), por lo tanto, se proponen las siguientes hipótesis:



H11: La Motivación Hedónica (MH) influye en la Intención de uso (IU)

H12: La Edad, el Género y la Experiencia del individuo moderan la influencia de la Motivación Hedónica (MH) en la Intención de uso (IU)

Valor – Precio (VP): En el contexto de los consumidores, hace referencia a la relación de compromiso entre el beneficio percibido por el usuario al usar la tecnología y el precio que paga por ello. Según (Dodds, Monroe, & Grewal, 1991) el precio puede ser tanto un indicador de la cantidad de sacrificio necesario para comprar un producto como un indicador del nivel de calidad. Cuando los beneficios percibidos de emplear una nueva tecnología superan al costo monetario de ésta, el valor del precio es positivo teniendo un impacto positivo en las tasas de intención de uso de nuevas tecnologías (Venkatesh, Thong, & Xu, 2012).

Diversos estudios han sugerido que el valor del precio percibido constituye un factor influyente en las intenciones de usar tecnologías digitales (Shen, X, Sotiriadis, & Wang, 2022) (Mehta, Morris, Swinnerton, & Homer, 2019) (Ain, Kaur, & Waheed, 2016)

Esta variable se encuentra moderada por el Género y la Edad del individuo (Venkatesh, Thong, & Xu, 2012), por lo que se proponen las siguientes hipótesis:

H13: El Valor – Precio (VP) influye en la Intención de uso (IU)

H14: La Edad y el Género del individuo moderan la influencia del Valor – Precio (VP) en la Intención de uso (IU)

Hábito (HT): El hábito se define como el grado en que las personas tienden a realizar comportamientos de manera automática debido al aprendizaje (Venkatesh, Thong, & Xu, 2012). Este factor busca reflejar los resultados de las experiencias adquiridas anteriormente y según esta definición el hábito en este estudio se definiría como la medida en que los individuos tienden a utilizar inteligencia artificial para crear contenido en redes sociales de forma automática.



Se espera que, de acuerdo con distintas investigaciones, si los individuos tienen un comportamiento más habitual hacia el uso del sistema, entonces es más probable que lo adopten y tengan intención de uso. (El-Masri & Tarhini, 2017) (Alalwan, Dwivedi, Rana, & Williams, 2016) (Jorge Arenas-Gaitán, 2015)

Esta variable es moderada por el Género, la Edad y Experiencia del individuo (Venkatesh, Thong, & Xu, 2012), por lo que se proponen las siguientes hipótesis:

H15: El Hábito (HT) influye en la Intención de uso (IU)

H16: El Hábito (HT) influye en la Conducta de uso (USO)

H17: La Edad, el Género y la Experiencia del individuo moderan la influencia del Hábito (HT) en la Intención de uso (IU)

H18: La Edad, el Género y la Experiencia del individuo moderan la influencia del Hábito (HT) en la Conducta de uso (USO)

INTENCIÓN DE USO (IU): En el contexto de este estudio, la Intención de uso (IU) hace referencia a las preferencias e intenciones de los individuos que reflejan la disposición hacia el uso y el esfuerzo de utilizar la inteligencia artificial para la creación de contenido en redes sociales. Se busca determinar cuáles variables son más importantes, observando cómo estas afectan en la aceptación e intención de uso de la tecnología.

Se espera que la intención de uso tenga una influencia positiva y significativa en el uso de la tecnología (Venkatesh, Morris, Davis, & Davis, 2003), por lo tanto, se proponen las siguientes hipótesis:

H19: La Intención de uso (IU) influye en la Conducta de uso (USO)

H20: La Experiencia del individuo modera la influencia de la Intención de uso (IU) en la Conducta de uso (USO)



CONDUCTA DE USO (USO): En este estudio, la Conducta de uso (USO) se define como el grado en que los individuos realmente sí utilizan la inteligencia artificial para crear contenido en redes sociales. Por lo tanto, puede ser una función de los constructos del modelo UTAUT 2 descritos anteriormente.

Capítulo V: Marco metodológico

En este capítulo se expone el diseño de la investigación, donde se explicarán los métodos utilizados para la recolección de la data, el diseño de un muestreo adecuado y las técnicas utilizadas para el análisis de la información recolectada.

La presente investigación considera una fase exploratoria y una fase de análisis factorial confirmatorio, en la fase exploratoria se inicia una extensa revisión bibliográfica del contexto a nivel de antecedentes de las redes sociales en Chile, la creación de contenido y el uso de inteligencia artificial, su funcionamiento, capacidades y modelos de aceptación y uso de tecnologías útiles para el estudio. Se deduce de la información obtenida que el uso de inteligencia artificial para la creación de contenido en redes sociales ha tenido un crecimiento exponencial los últimos años, demostrando un gran interés por parte de la población a utilizarla para conocer su potencial, por lo que nace la necesidad de identificar los factores que inciden en la aceptación y el uso de esta nueva tecnología en los usuarios.

El modelo que se decide utilizar es el modelo UTAUT2, una extensión del modelo UTAUT el cual engloba otros modelos sobre la aceptación e intención de uso de tecnologías, pero en un contexto de consumo y ha demostrado tener un poder explicativo sólido, abarcando factores que son relevantes para la investigación. De acuerdo con esto, se trabaja bajo un enfoque confirmatorio de la teoría existente aplicada a un tema de investigación no explorado con anterioridad, para la construcción de un modelo estadístico que explique la varianza en la intención de implementar IA para la creación de contenido.



Para esto, se diseñó un cuestionario UTAUT2 basado en una investigación de (Nikolopoulou, Gialamas, & Lavidas, 2020) y adaptándolo al contexto del uso de la inteligencia artificial para la creación de contenido en redes sociales. Antes de aplicar la encuesta a la población objetivo, se consideró crucial realizar una validación a fin de juzgar la duración, simplicidad y claridad del cuestionario mediante una prueba exploratoria, en la cual se procedió a encuestar de manera preliminar a 10 personas solicitando una retroalimentación de esta. Se logró identificar preguntas ambiguas, corrigiendo aspectos de redacción de estas y dando una mejor presentación a la encuesta para evitar confusiones durante su desarrollo. Luego con información recolectada de un total de 100 participantes se procede a realizar una prueba de confiabilidad para realizar ajustes en los constructos en caso de ser necesario.

Luego de la validación de la encuesta preliminar, se procede a realizar la difusión de la encuesta para la recolección de datos a gran escala, la cual fue difundida mediante redes sociales mediante un muestreo por conveniencia para lograr llegar de mejor manera al público objetivo.

Concluida la recolección de datos, se procede a un análisis descriptivo y estadístico para evaluar la aceptación de la inteligencia artificial como herramienta para la creación de contenido en redes sociales mediante el uso del programa gratuito JASP de código abierto para análisis estadístico y la aplicación del modelo de ecuaciones estructurales (SEM), como también el uso de SPSS AMOS para una mejor visualización de los diagramas de senderos. Se busca realizar un análisis que determine si el modelamiento es adecuado o debe sufrir alguna modificación y realizar el ajuste en las variables si este lo necesita. A partir de los resultados se procede a la interpretación y conclusión respecto a las hipótesis planteadas y los objetivos de la investigación para generar recomendaciones adecuadas.

Método recolección de datos

La recolección de datos para esta investigación fue a través de encuestas realizadas de forma remota vía redes sociales y basadas en un cuestionario UTAUT 2 validado. Las razones para elegir este método de recolección de datos se basan en los siguientes puntos:



- **Costo de la difusión:** Debido a las características de las redes sociales, los costos para poder difundir a gran escala la encuesta son relativamente bajos y en ocasiones nulo, ya que existen plataformas donde es posible conectar con una gran cantidad de personas y lograr la masificación de información, archivos o en este caso encuestas de manera gratuita sin necesidad de contratar un servicio de pago.
- **Tamaño de la muestra:** Debido al alcance que se logran obtener mediante la difusión en redes sociales, es posible llegar a un grupo de personas de interés realmente amplio, de forma efectiva y dirigida.
- **Filtro de interés:** Dadas la naturaleza de las encuestas, es posible agregar preguntas que funcionen como filtro para la focalización en los grupos de interés y poder trabajar con una muestra más limpia, si la población de estudio es relativamente homogénea, este método puede proporcionar resultados razonablemente representativos.
- **Rapidez y facilidad:** Es un método rápido y sencillo de implementar, lo que permite obtener datos en poco tiempo. Además, los encuestados pueden responder en el momento que les resulte más conveniente.
- **Posibilidad de viralización:** Si el tema es interesante, los mismos participantes pueden compartir la encuesta, ampliando su alcance.

Durante la elaboración del cuestionario existieron 3 fases claves. La primera consiste en presentar a un grupo controlado de 10 personas la encuesta con la finalidad de generar una retroalimentación sobre diversos aspectos de la encuesta en base a la redacción, duración y sugerencias. Otra fase de análisis preventivo donde se reunió información de un total de 100 participantes para realizar un análisis de confiabilidad de los constructos de manera que, si existe necesidad, realizar ajustes. Y por último una fase final, donde en base a la retroalimentación recibida en las fases anteriores, se realizaron los ajustes necesarios y se procedió a la difusión en redes sociales, controlando siempre que esta llegase principalmente al grupo de interés el cuales son los usuarios que utilizan la inteligencia artificial para crear contenido en redes sociales.



Diseño de muestreo

Público objetivo

Entendiendo el contexto de consumo del estudio, el público objetivo al que se apunta es a usuarios que utilicen redes sociales en su día a día y que tengan un interés por utilizar herramientas para crear contenido en ellas. Debido a que los jóvenes son más propensos a utilizar redes sociales de forma más activa se espera que el público objetivo sea un público joven ya que crecieron en un entorno tecnológico que los hace poseer un mayor conocimiento y mantengan un interés por mantenerse actualizados con las últimas tecnologías.

Localización de la muestra

Los datos recopilados provienen de una encuesta en línea difundida principalmente mediante redes sociales, por lo que las participaciones abarcan potencialmente todo el territorio nacional, diversos estratos socioeconómicos, creencias y rangos de edad. No obstante, debido a la naturaleza de estas plataformas digitales, la población encuestada se concentra en un segmento más juvenil, aunque igualmente diversificado. Considerando estas circunstancias, es razonable inferir que la información obtenida constituirá una adecuada representación conceptual del público objetivo relevante para la investigación.

Técnica de muestro y tamaño de la muestra

Se utiliza el muestreo por conveniencia, la cual es una técnica de muestreo no probabilística y no aleatoria donde los participantes se seleccionan por su accesibilidad y proximidad. Esta elección se debe a que es más práctico y rápido acceder a la población de interés, obteniendo información de los participantes que se encuentren disponibles y estén dispuestos a participar de la investigación. Si bien la muestra puede no reflejar adecuadamente a la población general, lo que limita la generalización de los resultados. Se procura utilizar múltiples plataformas y medios para distribuir la encuesta, como también, conseguir una muestra del mayor tamaño posible para así alcanzar diferentes segmentos de la población e incorporar el máximo azar posible para lograr un equilibrio en la diversidad de participantes que logre mitigar esta falta de representatividad.



El tamaño de la muestra de una encuesta es muy importante para poder realizar una investigación de manera correcta, al utilizarse este método de muestreo por conveniencia, no existe un respaldo matemático para la cantidad mínima de encuestas a realizarse, aunque (QuestionPro, 2024) ofrece una sugerencia para obtener un tamaño de muestra que sea lo suficientemente adecuada para obtener resultados que disminuyan el margen de error siguiendo los siguientes pasos:

- **Elegir el nivel de confianza:** Es el grado de certeza (o probabilidad) expresado como porcentaje con el que se puede afirmar que un parámetro se encuentra dentro de un intervalo estimado a partir de una muestra. El nivel de confianza más utilizado y efectivo es de un 95%.
- **Definir el margen de error:** Es un indicador de la fiabilidad del estudio y de la exactitud de los resultados. Se expresa como un porcentaje que indica que los resultados obtenidos están dentro de este rango de valores por encima o por debajo. Generalmente se establece en un 5%.
- **Asignar el total de la población.** En este paso es fundamental el apoyo en datos oficiales de un aproximado del tamaño de la población total que utiliza las redes sociales para crear contenido. De acuerdo con (Statista Research Department, 2024), alrededor de un 84,5% de los habitantes chilenos interactúan en estas plataformas de redes sociales, lo que equivaldría a un aproximado de 16,5 millones de usuarios. Y de acuerdo con los datos actualizados de (Influencity, 2024) Se calcula que en Chile hay, aproximadamente, más de 607.900 creadores de contenido, por lo que asumiremos este valor como aproximado de la población total.
- **Asignar probabilidades de ocurrencia:** Como en nuestro caso de investigación se desconoce la probabilidad de que ocurra el evento, se asigna un 50% a la probabilidad de éxito "p" y un 50% a la probabilidad de fracaso "q".



La fórmula por utilizar es la siguiente:

$$n = \frac{N * Z_{\alpha}^2 * p * q}{e^2 * (N - 1) + Z_{\alpha}^2 * p * q}$$

n = Tamaño de muestra buscado

N = Tamaño de la Población o Universo

z = Parámetro estadístico que depende el Nivel de Confianza (NC)

e = Error de estimación máximo aceptado

p = Probabilidad de que ocurra el evento estudiado (éxito)

q = (1 - p) = Probabilidad de que no ocurra el evento estudiado

Fig. 16. Cómo calcular el tamaño de muestra para una población finita.

Figura obtenida de Fuente: (QuestionPro, 2024)

A partir de la información y antecedentes obtenidos, se obtiene que un valor de 384 encuestas respondidas es un valor adecuado y representativo de la población, asumiendo un nivel de confianza de un 95% y un margen de error del 5%.

Tomando en cuenta a (Jackson, 2003), recomienda un mínimo de 200 sujetos para cualquier SEM. Mientras que siguiendo los ratios recomendados por (Hinkin, 1995) se debe obtener de 1 a 10 respuestas por ítem de la encuesta a realizarse, para este caso de investigación se cuenta con 29 ítems relacionados al cuestionario UTAUT2 y 4 preguntas de tipo demográfico, dando como resultado un total 33 ítems, por lo tanto, de acuerdo con lo que se indica, un buen número sería de 330 encuestas respondidas. (Kline R. B., 2005) propone que se debe obtener de 10-20 participantes, suponiendo entre 330 y 660 encuestas respondidas un valor adecuado para alcanzar una muestra lo suficientemente representativa y significativa para obtener resultados confiables.

Concluyendo así de los diferentes investigadores y fuentes que un número entre 200 y 660 participantes pueden ser adecuados para esta investigación. De todas maneras, y a modo de obtener una mayor potencia estadística y representatividad, se buscará obtener la mayor cantidad de encuestas respondidas.



Instrumento de investigación

El principal instrumento de investigación fue el cuestionario UTAUT2 el cual fue difundido de manera remota vía redes sociales. Este se basa en un cuestionario correspondiente a una investigación de (Nikolopoulou, Gialamas, & Lavidas, 2020) y adaptado al contexto de la inteligencia artificial para crear contenido en redes sociales.

Dicho cuestionario consiste en 33 preguntas, dentro de las cuales 29 corresponden a los constructos o variables del modelo y 4 para estudiar las variables moderadoras como la edad, género y experiencia. La escala de medición que utiliza el cuestionario es una escala Likert de 1 a 7 puntos, siendo estos desde “Totalmente en desacuerdo” hasta “Totalmente de acuerdo” respectivamente. La encuesta se constituye de 2 partes, una con orientación a preguntas demográficas y otra orientada al cuestionario UTAUT2.

Factor	Variable	Pregunta
Edad	Edad	Indica tu edad
Género	Gen	Soy: Hombre ó Mujer
Experiencia	Exp1	¿He utilizado la inteligencia artificial anteriormente para crear contenido en redes sociales?
	Exp2	De ser así, ¿Qué tipo de contenido para redes sociales ha creado con ayuda de la inteligencia artificial?

Tabla 3. Perfil demográfico de la encuesta realizada.

Fuente: *Elaborada para esta investigación.*

Factor	Variable	Pregunta
Expectativa de rendimiento	ER1	La IA me resulta <u>útil</u> para crear contenido en redes sociales
	ER2	El uso de IA me ayuda a realizar diversas actividades relacionadas con la creación de contenidos en las redes sociales <u>más rápido</u>
	ER3	Usar IA incrementa mi <u>productividad</u>
	ER4	Usar IA aumenta mis posibilidades de lograr cosas que son importantes para mí
Expectativa del esfuerzo	EE1	<u>Aprender a usar</u> la IA para crear contenido en redes sociales es fácil para mí
	EE2	La IA es fácil de usar en la creación de contenido en redes sociales
	EE3	Sería fácil para mí volverme hábil en el uso de la IA para crear contenido en redes sociales
	EE4	Mi interacción con la IA es clara y comprensible
Influencia social	IS1	Personas importantes para mí piensan que yo debería usar IA para crear contenido en redes sociales
	IS2	Personas que influyen mi comportamiento piensan que yo debería usar la IA para crear contenido en redes sociales
	IS3	Las personas cuyas opiniones valoro, prefieren que use la IA para crear contenido en redes sociales
Condiciones facilitadoras	CF1	Tengo los <u>recursos</u> necesarios para utilizar la IA en las creación de contenido para redes sociales
	CF2	Tengo el <u>conocimiento</u> necesario para usar la IA en la creación de contenido para redes sociales
	CF3	La IA es <u>compatible</u> con otras tecnologías que uso para crear contenido en redes sociales.
	CF4	Puedo obtener ayuda de otros cuando tengo dificultades para usar la IA para la creación de contenido en redes sociales
Motivación Hedónica	MH1	Usar IA para crear contenido en redes sociales es agradable
	MH2	Usar IA para crear contenido en redes sociales es divertido
	MH3	Usar IA para crear contenido en redes sociales es placentero
Valor-Precio	VP1	La IA para crear contenido en redes sociales tiene un precio razonable
	VP2	La IA para crear contenido en redes sociales ofrece una buena relación calidad-precio
	VP3	El coste actual de los servicios a los que tengo acceso a través del uso de la IA para crear contenido en redes sociales vale su dinero
Hábito	HT1	Soy adicto a usar la IA para crear contenido en redes sociales
	HT2	El uso de IA para crear contenido en redes sociales se ha vuelto un hábito para mí
	HT3	Usar la IA para crear contenido en redes sociales se ha vuelto una necesidad para mí
Intención de uso	IU1	Siempre intentaré utilizar la IA para crear contenido en redes sociales
	IU2	Tengo la intención de usar la IA en el futuro para crear contenido en redes sociales
	IU3	Planeo usar la IA con frecuencia para crear contenido en redes sociales
Conducta de uso	USO1	Actualmente utilizo la IA como herramienta de apoyo en la creación de contenido en redes sociales
	USO2	Dedico mucho tiempo al uso de la IA para la creación de contenido en redes sociales

Tabla 4. Encuesta adaptada al contexto de IA para crear contenido en redes sociales

Fuente: *Elaborada para esta investigación.*

Análisis de datos

Análisis descriptivo

El principal objetivo de este análisis es obtener información sobre el perfil demográfico de los encuestados, ya sea su edad, género y experiencia con relación al uso de inteligencia artificial. El análisis será realizado en base a tablas y gráficos, usando herramientas estadísticas descriptivas como la frecuencia, porcentajes, promedio, entre otras, como base para construir estas.



Validación de datos

Primeramente, se realizará la identificación del modelo, es decir, determinar la capacidad del modelo de estimar los parámetros de manera única a partir de los datos disponibles. Para esto, la regla fundamental para determinar es que los grados de libertad (g.l.) sean mayores o iguales a cero.

Luego para la validación de los datos obtenidos, estos serán sometidos a una prueba de fiabilidad y un análisis de multicolinealidad. La confiabilidad o fiabilidad, se refiere a la consistencia o estabilidad de una medida, por lo tanto, la prueba de fiabilidad está orientada para determinar si los datos recolectados son consistentes, para ello se aplica el Alfa de Cronbach, cuyos valores de acuerdo con (George & Mallery, 2003) son los siguientes:

Interpretación del estadístico Alfa de Cronbach	
Rangos	Interpretación
Menor a 0,50	Confiabilidad no aceptable
0,50 a 0,59	Confiabilidad pobre
0,60 a 0,69	Confiabilidad cuestionable
0,70 a 0,79	Confiabilidad aceptable
0,80 a 0,89	Confiabilidad buena
0,90 a 1,00	Confiabilidad excelente

Tabla 5. Interpretación del estadístico Alfa de Cronbach

Fuente: (George & Mallery, 2003)

El análisis de la multicolinealidad es un paso crítico en la investigación estadística, especialmente antes de realizar un análisis de regresión o evaluar las relaciones entre variables. La multicolinealidad ocurre cuando dos o más variables independientes en un modelo de regresión están altamente correlacionadas, lo que puede llevar a estimaciones inexactas de los coeficientes de regresión y a una interpretación errónea de los resultados.



Para evaluar la multicolinealidad se utilizará el método de correlación de Pearson, este coeficiente mide la relación lineal entre dos variables. Un valor cercano a +1 o -1 indica una fuerte correlación, mientras que un valor cercano a 0 sugiere poca o ninguna correlación. Debido a que existen diversos investigadores que proponen diferentes rangos y escalas para las correlaciones (Roy-García, Rivas-Ruiz, Pérez-Rodríguez, & Palacios-Cruz, 2019) (Shrestha, 2020) (Kline R. B., 2011) (Hair, Black, Babin, & Anderson, 2010), a modo de equilibrio entre las diferentes proposiciones se buscarán valores menores a 0.9 para las correlaciones entre variables para evitar la multicolinealidad.

Análisis SEM

Se realizará un análisis SEM para estudiar las relaciones entre las variables del modelo y los factores moderadores a modo de verificar las diferentes hipótesis planteadas y comprobar si se cumplen o no. Este análisis estadístico permite medir las relaciones cuantitativas entre las variables y revelar las interacciones entre las variables independientes y dependientes.

Al modelar datos categóricos ordenados, si las variables tienen cinco categorías o más, los datos son aproximadamente de distribución normal. Se recomienda tratar los datos como continuos por naturaleza y emplear la estimación de Máxima Verosimilitud (ML) (Finney & DiStefano, 2006) (Rhemtulla, Brosseau-Liard, & Savalei, 2012).

Primeramente, se generará un diagrama de senderos que ilustre y explique la relación entre las variables y constructos del modelo base. Luego se aplicará el modelo SEM, donde para que los resultados del análisis sean estadísticamente significativos, se requerirá que el valor p sea menor a 0.05, lo que implicaría que las hipótesis planteadas son aceptadas, o que la hipótesis nula puede ser rechazada.

Para asegurar la solidez del modelo se realizarán ajustes de bondad, los cuales son indicadores que permiten evaluar qué tan bien se ajusta el modelo empírico seleccionado a la información recopilada durante el estudio. Estos ajustes brindarán información valiosa para determinar si el modelo necesita modificaciones o ajustes adicionales.



Si el modelo necesita ser modificado debido a relaciones que no sean estadísticamente significativas o por mal ajuste de bondad se volverá a proponer un modelo nuevo excluyendo estas variables que no demostraron significancia con el objetivo de mejorar la relevancia estadística. Se le aplicará nuevamente ajustes de bondad con la finalidad de comparar y analizar si los cambios realizados son acertados y logran mejorar estos valores estadísticos.

También se llevará a cabo un análisis de moderación para examinar el efecto de las variables edad, género y experiencia en las relaciones entre las variables presentes en el modelo. El análisis de la moderación se realiza con las variables del modelo modificado ya que afecta únicamente a las relaciones que son estadísticamente significativas. Por lo tanto, es fundamental identificar primero cuáles relaciones del modelo base son significativas. Además, es importante tener en cuenta que la moderación afecta el valor y/o la dirección de las relaciones, pero no determina si estas relaciones existen o no.

Finalmente, se presentará una estimación definitiva del modelo estudiado, incorporando las variables significativas y los efectos moderadores que se haya identificado como significativos. A partir de este se realizará un análisis de las hipótesis planteadas en un comienzo y poder generar recomendaciones para posibles estudios futuros relacionados.

Capítulo VI: Estudio empírico y resultados

Validación de datos etapa de análisis preventivo

Primeramente, se llevó a cabo una encuesta piloto con una muestra reducida de 10 personas para obtener una retroalimentación y sugerencias en cuanto a la redacción, duración y comprensión de las preguntas. Se lograron recopilar algunas sugerencias que hacían énfasis en facilitar la comprensión de la intención real del cuestionario, como también ajustes en la redacción para que a la hora de responder sea más fácil entender las preguntas. En consecuencia, se implementaron los cambios pertinentes para simplificar el proceso de respuesta de los participantes y eliminar posibles ambigüedades durante la encuesta.



A partir de estos cambios se procedió a obtener una muestra aún más grande, obteniendo 100 respuestas con las cuales se pudo realizar un análisis de fiabilidad a través del Alfa de Cronbach, coeficiente utilizado para evaluar la consistencia interna de las preguntas y que para esta investigación servirá de gran ayuda para tener una primera mirada respecto de si los factores utilizados son sólidos o no.

A continuación, se presentan los resultados del alfa de Cronbach para cada uno de los constructos, además, se realiza un análisis de sensibilidad para evaluar cómo cambian estos valores si se eliminan variables que pertenecen al constructo.

Expectativa de rendimiento

Estadísticas de confiabilidad de la escala frecuente

Estimar	Cronbach's α
Estimación por punto	0.820

Estadísticas de confiabilidad de ítems individuales frecuentes

Ítem	si se elimina el ítem
	Cronbach's α
La IA me resulta útil para crear contenido en redes sociales	0.742
El uso de IA me ayuda a realizar diversas actividades relacionadas con la creación de contenidos en las redes sociales más rápido	0.822
Usar IA incrementa mi productividad	0.780
Usar IA aumenta mis posibilidades de lograr cosas que son importantes para mí.	0.745

Fig. 17. Test fiabilidad variable expectativa de rendimiento (Encuesta piloto)

Figura obtenida con Jasp.

Como se puede observar en la Figura 17, el valor para el Alfa de Cronbach del constructo Expectativa de rendimiento es de 0.820, interpretándose como una confiabilidad buena de acuerdo con (George & Mallery, 2003). Además, el análisis de sensibilidad indica que al eliminar la variable ER2 (El uso de IA me ayuda a realizar diversas actividades relacionadas con la creación de contenidos en las redes sociales más rápido) el valor del Alfa de Cronbach sólo aumenta un 0.002, el cual es un valor muy bajo por lo tanto no se realizarán ajustes.



Expectativa del esfuerzo

Estadísticas de confiabilidad de la escala frecuente

Estimar	Cronbach's α
Estimación por punto	0.798

Estadísticas de confiabilidad de ítems individuales frecuentes

Ítem	si se elimina el ítem
	Cronbach's α
Aprender a usar la IA para crear contenido en redes sociales es f.cil para m.	0.746
La IA es f.cil de usar en la creaci.n de contenido en redes sociales	0.737
Ser.a f.cil para m. volverme h.bil en el uso de la IA para crear contenido en redes sociales	0.776
Mi interacci.n con la IA es clara y comprensible	0.726

Fig. 18. Test fiabilidad variable expectativa del esfuerzo (Encuesta piloto)

Figura obtenida con Jasp.

Como se puede observar en la Figura 18, el valor para el Alfa de Cronbach del constructo Expectativa del esfuerzo es de 0.798, interpretándose como una confiabilidad aceptable casi buena de acuerdo con (George & Mallery, 2003). Además, el análisis de sensibilidad indica que no existe ninguna variable que al ser eliminada logre aumentar su valor.

Influencia social

Estadísticas de confiabilidad de la escala frecuente

Estimar	Cronbach's α
Estimación por punto	0.924

Estadísticas de confiabilidad de ítems individuales frecuentes

Ítem	si se elimina el ítem
	Cronbach's α
Personas importantes para m. piensan que yo deber.a usar IA para crear contenido en redes sociales	0.895
Personas que influyen mi comportamiento piensan que yo deber.a usar la IA para crear contenido en redes sociales	0.873
Las personas cuyas opiniones valoro, prefieren que use la IA para crear contenido en redes sociales	0.903

Fig. 19. Test fiabilidad variable influencia social (Encuesta piloto)

Figura obtenida con Jasp.

Como se puede observar en la Figura 19, el valor para el Alfa de Cronbach del constructo Influencia social es de 0.924, interpretándose como una confiabilidad excelente de acuerdo con (George & Mallery, 2003). Además, el análisis de sensibilidad indica que no existe ninguna variable que al ser eliminada logre aumentar su valor.



Condiciones facilitadoras

Estadísticas de confiabilidad de la escala frecuente

Estimar	Cronbach's α
Estimación por punto	0.769

Estadísticas de confiabilidad de ítems individuales frecuentes

Ítem	si se elimina el ítem
	Cronbach's α
Tengo los recursos necesarios para utilizar la IA en las creación de contenido para redes sociales	0.704
Tengo el conocimiento necesario para usar la IA en la creación de contenido para redes sociales	0.696
La IA es compatible con otras tecnologías que uso para crear contenido en redes sociales.	0.711
Puedo obtener ayuda de otros cuando tengo dificultades para usar la IA para la creación de contenido en redes sociales	0.751

Fig. 20. Test fiabilidad variable condiciones facilitadoras (Encuesta piloto)

Figura obtenida con Jasp.

Como se puede observar en la Figura 20, el valor para el Alfa de Cronbach del constructo Condiciones facilitadoras es de 0.769, interpretándose como una confiabilidad aceptable de acuerdo con (George & Mallery, 2003). Además, el análisis de sensibilidad indica que no existe ninguna variable que al ser eliminada logre aumentar su valor.

Motivación hedónica

Estadísticas de confiabilidad de la escala frecuente

Estimar	Cronbach's α
Estimación por punto	0.892

Estadísticas de confiabilidad de ítems individuales frecuentes

Ítem	si se elimina el ítem
	Cronbach's α
Usar IA para crear contenido en redes sociales es agradable	0.819
Usar IA para crear contenido en redes sociales es divertido	0.836
Usar IA para crear contenido en redes sociales es placentero	0.893

Fig. 21. Test fiabilidad variable motivación hedónica (Encuesta piloto)

Figura obtenida con Jasp.

Como se puede observar en la Figura 21, el valor para el Alfa de Cronbach del constructo Motivación hedónica es de 0.892, interpretándose como una confiabilidad buena casi excelente de acuerdo con (George & Mallery, 2003). Además, el análisis de sensibilidad indica que al eliminar la variable MH3 (Usar IA para crear contenido en redes sociales es placentero) el valor del Alfa de Cronbach sólo aumenta un 0.001, el cual es un valor muy bajo por lo tanto no se realizarán ajustes.



Valor – Precio

Estadísticas de confiabilidad de la escala frecuente

Estimar	Cronbach's α
Estimación por punto	0.871

Estadísticas de confiabilidad de ítems individuales frecuentes

Ítem	si se elimina el ítem	
	Cronbach's α	
La IA para crear contenido en redes sociales tiene un precio razonable	0.815	
La IA para crear contenido en redes sociales ofrece una buena relación calidad-precio	0.764	
El coste actual de los servicios a los que tengo acceso a través del uso de la IA para crear contenido en redes sociales vale su dinero	0.876	

Fig. 22. Test fiabilidad variable valor-precio (Encuesta piloto)

Figura obtenida con Jasp.

Como se puede observar en la Figura 22, el valor para el Alfa de Cronbach del constructo Valor - precio de rendimiento es de 0.871, interpretándose como una confiabilidad buena de acuerdo con (George & Mallery, 2003). Además, el análisis de sensibilidad indica que al eliminar la variable VP3 (El coste actual de los servicios a los que tengo acceso a través del uso de la IA para crear contenido en redes sociales vale su dinero) el valor del Alfa de Cronbach sólo aumenta un 0.005, el cual es un valor muy bajo por lo tanto no se realizarán ajustes.

Hábito

Estadísticas de confiabilidad de la escala frecuente

Estimar	Cronbach's α
Estimación por punto	0.932

Estadísticas de confiabilidad de ítems individuales frecuentes

Ítem	si se elimina el ítem	
	Cronbach's α	
Soy adicto a usar la IA para crear contenido en redes sociales	0.906	
El uso de IA para crear contenido en redes sociales se ha vuelto un hábito para mí.	0.889	
Usar la IA para crear contenido en redes sociales se ha vuelto una necesidad para mí.	0.908	

Fig. 23. Test fiabilidad variable hábito (Encuesta piloto)

Figura obtenida con Jasp.



Como se puede observar en la Figura 23, el valor para el Alfa de Cronbach del constructo Hábito es de 0.932, interpretándose como una confiabilidad excelente de acuerdo con (George & Mallery, 2003). Además, el análisis de sensibilidad indica que no existe ninguna variable que al ser eliminada logre aumentar su valor.

Intención de uso

Estadísticas de confiabilidad de la escala frecuente

Estimar	Cronbach's α
Estimación por punto	0.863

Estadísticas de confiabilidad de ítems individuales frecuentes

Ítem	si se elimina el ítem
	Cronbach's α
Siempre intentar. utilizar la IA para crear contenido en redes sociales	0.891
Tengo la intención de usar la IA en el futuro para crear contenido en redes sociales	0.822
Planeo usar la IA con frecuencia para crear contenido en redes sociales	0.690

Fig. 24. Test fiabilidad variable intención de uso (Encuesta piloto)

Figura obtenida con Jasp.

Como se puede observar en la Figura 24, el valor para el Alfa de Cronbach del constructo Intención de uso es de 0.863, interpretándose como una confiabilidad buena de acuerdo con (George & Mallery, 2003). Además, el análisis de sensibilidad indica que al eliminar la variable IU1 (Siempre intentaré utilizar la IA para crear contenido en redes sociales) el valor del Alfa de Cronbach sólo aumenta un 0.028, el cual es un valor bajo que no permite tampoco cambiar a una categoría de confiabilidad excelente, por lo tanto, no se realizarán ajustes.

Conducta de uso

Estadísticas de confiabilidad de la escala frecuente

Estimar	Cronbach's α
Estimación por punto	0.877

Fig. 25. Test fiabilidad variable conducta de uso (Encuesta piloto)

Figura obtenida con Jasp.



Como se puede observar en la Figura 25, el valor para el Alfa de Cronbach del constructo Conducta de uso es de 0.877, interpretándose como una confiabilidad buena de acuerdo con (George & Mallery, 2003).

A partir del análisis del Alfa de Cronbach de todos los constructos, es posible concluir que las preguntas del cuestionario logran medir de manera consistente el constructo al que hacen referencia como también se concluye que los factores utilizados son sólidos, por lo tanto, es posible continuar con la etapa de la difusión masiva de la encuesta para el análisis posterior.

Análisis base de datos recolectada

Como se dijo anteriormente, las encuestas de retroalimentación y piloto fueron de gran utilidad para evaluar la claridad y la comprensión del cuestionario, además de poder evaluar la fiabilidad de los constructos a través de la prueba del alfa de Cronbach que tiene la utilidad de brindar una primera mirada acerca de si los factores utilizados son sólidos o no.

Luego del análisis, se procedió a difundir la encuesta a gran escala con la finalidad de obtener la mayor cantidad de participantes. Se obtuvieron un total de 406 respuestas que servirán de utilidad para poder evaluar los distintos factores sobre la intención y la conducta de uso mediante el programa JASP.

Análisis descriptivo

De las 406 respuestas, de acuerdo con la Tabla 6, un 48,8% son hombres, mientras que un 51,2% de la muestra son mujeres. Mientras que la edad de los encuestados varía entre los 13 y los 68 años. De acuerdo con la Tabla 7 El rango de edad entre 18 y 24 años es el con mayor frecuencia, con un 64,8% del total de las encuestas, seguido por el rango de personas con una edad entre 25 a 34 años que representan un 26,6%. En conclusión, con estos datos recopilados se puede validar que el público objetivo fue prácticamente acertado ya que se buscaba llegar a un público joven ya que eran más propensos a utilizar las redes sociales y conocer nuevas tecnologías.



Género	Frecuencia	Porcentaje
Hombre	198	48,8%
Mujer	208	51,2%

Tabla 6. Información de la cantidad de hombres y mujeres de la muestra

Fuente: Elaboración propia

Edad	Frecuencia	Porcentaje
Menos de 18 años	10	2,5%
18 a 24 años	263	64,8%
25 a 34 años	108	26,6%
35 a 44 años	20	4,9%
Más de 44 años	5	1,2%

Tabla 7. Información de las edades por tramos de la muestra.

Fuente: Elaboración propia

Con respecto a la experiencia de uso la Tabla 8 indica que un 70,7%, lo que equivale a 287 de los encuestados, sí ha utilizado IA para crear contenido en redes sociales al menos alguna vez.

¿He utilizado la IA anteriormente para crear contenido en redes sociales?		
Experiencia	Frecuencia	Porcentaje
Sí	287	70,7%
No	119	29,3%

Tabla 8. Información sobre la experiencia de la muestra.

Fuente: Elaboración propia

Un análisis extra que se realizó fue sobre con que propósito era utilizada la IA, que tipo de contenido era el más creado por parte de los encuestados con ayuda de la IA para sus redes sociales. En cada respuesta se podía seleccionar más de una opción. Los resultados destacan la redacción de publicaciones como lo más utilizado (43,3%), seguido de la edición y mejora de fotos existentes (38,5%) y la generación de imágenes originales (32,6%). Cabe destacar que con un 27,1% existen otros tipos de contenidos creados con ayuda de la IA que no estaban dentro de las opciones.



¿Qué tipo de contenido para redes sociales he creado con ayuda de IA?		
Propósito	Frecuencia	Porcentaje
Redacción de publicaciones	124	43,3%
Generación de imágenes originales	94	32,6%
Edición y mejora de fotos existentes	110	38,5%
Edición automatizada de clips	33	11,4%
Generación de música de fondo	43	15,1%
Conversión de texto a voz para narraciones	79	27,4%
Análisis de tendencias y temas populares	43	15,1%
Recomendaciones personalizadas de contenido	65	22,8%
Otros	78	27,1%

Tabla 9. Información sobre los propósitos más utilizados de la IA.

Fuente: Elaboración propia

Validación de datos

Los resultados del análisis de fiabilidad se presentan en la Tabla 10, donde se muestran los coeficientes alfa de Cronbach para cada variable del estudio. El constructo "Hábito" obtuvo el valor más alto con 0.939, mientras que el constructo "Condiciones Facilitadoras" registró el más bajo con 0.763. Según los criterios establecidos por (George & Mallery, 2003), todos los constructos superan el umbral de aceptabilidad (0.70), con la mayoría alcanzando niveles de confiabilidad considerados buenos (por encima de 0.80) e incluso excelentes (superando 0.90) en algunos casos. Estos resultados respaldan la fiabilidad de los datos recopilados en la investigación.

Es importante señalar que se identificó solo una variable cuya eliminación podría mejorar marginalmente el coeficiente alfa de Cronbach de su constructo correspondiente. Esta es la variable denominada IU1 ("Siempre intentaré utilizar la IA para crear contenido en redes sociales") y dado que la mejora potencial es mínima (0.021) y no altera significativamente la interpretación de la confiabilidad, se decidió mantener esta variable en el modelo de estudio.



Constructos	VARIABLES OBSERVABLES	Ajuste en el índice al eliminar la variable	Alfa de Cronbach
Expectativa de rendimiento	ER1	0,783	0,843
	ER2	0,812	
	ER3	0,812	
	ER4	0,798	
Expectativa de esfuerzo	EE1	0,795	0,855
	EE2	0,808	
	EE3	0,839	
	EE4	0,817	
Influencia Social	IS1	0,906	0,934
	IS2	0,891	
	IS3	0,915	
Condiciones facilitadora	CF1	0,703	0,763
	CF2	0,685	
	CF3	0,694	
	CF4	0,744	
Motivación hedónica	MH1	0,809	0,879
	MH2	0,815	
	MH3	0,865	
Valor - Precio	VP1	0,806	0,852
	VP2	0,753	
	VP3	0,821	
Hábito	HT1	0,921	0,939
	HT2	0,901	
	HT3	0,911	
Intención de uso	IU1	0,89	0,869
	IU2	0,815	
	IU3	0,733	
Uso Real	USO1	-	0,811
	USO2	-	

Tabla 10. Alfa de Cronbach de los constructos y análisis de sensibilidad por variable.

Fuente: Elaboración propia

Análisis Multicolinealidad

La evaluación de la multicolinealidad se realizó mediante el análisis de las correlaciones entre las variables observables del modelo. Es importante destacar que este análisis no puede aplicarse directamente a las variables latentes, ya que estas son constructos teóricos no observables en los datos. Por lo tanto, el enfoque adoptado consiste en examinar las correlaciones entre las variables observadas asociadas a cada variable latente en el modelo propuesto. Para considerar que no existen problemas significativos de multicolinealidad, se establece como criterio que las correlaciones entre variables no deben superar el valor de 0.90.



Los resultados del análisis, presentados en las Tablas 11 y 12 muestran que las correlaciones entre las variables del estudio oscilan entre 0.147 y 0.844. Estos valores se encuentran por debajo del umbral crítico, lo que sugiere que no hay indicios de multicolinealidad que pudieran afectar negativamente la validez del modelo propuesto.

	ER1	ER2	ER3	ER4	EE1	EE2	EE3	EE4	IS1	IS2	IS3	CF1	CF2	CF3	CF4
ER1	—														
ER2	0.725	—													
ER3	0.530	0.473	—												
ER4	0.576	0.493	0.664	—											
EE1	0.451	0.437	0.439	0.409	—										
EE2	0.407	0.510	0.419	0.440	0.665	—									
EE3	0.395	0.396	0.406	0.381	0.581	0.545	—								
EE4	0.523	0.480	0.447	0.464	0.632	0.608	0.539	—							
IS1	0.320	0.326	0.313	0.376	0.256	0.207	0.231	0.204	—						
IS2	0.344	0.328	0.303	0.385	0.261	0.192	0.222	0.246	0.844	—					
IS3	0.346	0.327	0.285	0.375	0.204	0.195	0.209	0.211	0.804	0.829	—				
CF1	0.285	0.317	0.286	0.241	0.394	0.426	0.390	0.428	0.163	0.188	0.147	—			
CF2	0.292	0.292	0.323	0.265	0.556	0.475	0.423	0.583	0.229	0.233	0.200	0.534	—		
CF3	0.397	0.428	0.408	0.333	0.480	0.433	0.448	0.481	0.257	0.310	0.264	0.478	0.465	—	
CF4	0.315	0.312	0.286	0.343	0.366	0.411	0.377	0.402	0.304	0.371	0.348	0.344	0.417	0.446	—

Tabla 11. Matriz de correlación de Pearson por variable observable.

Fuente: Elaboración propia

	MH1	MH2	MH3	VP1	VP2	VP3	HT1	HT2	HT3	IU1	IU2	IU3	USO1	USO2
MH1	—													
MH2	0.762	—												
MH3	0.695	0.689	—											
VP1	0.393	0.362	0.366	—										
VP2	0.531	0.514	0.494	0.697	—									
VP3	0.468	0.426	0.494	0.606	0.677	—								
HT1	0.322	0.307	0.380	0.315	0.323	0.373	—							
HT2	0.395	0.355	0.424	0.303	0.319	0.384	0.839	—						
HT3	0.312	0.286	0.369	0.276	0.260	0.318	0.820	0.854	—					
IU1	0.352	0.306	0.386	0.301	0.307	0.381	0.681	0.738	0.698	—				
IU2	0.448	0.428	0.382	0.337	0.383	0.383	0.438	0.505	0.445	0.579	—			
IU3	0.478	0.429	0.444	0.333	0.406	0.434	0.536	0.591	0.544	0.687	0.802	—		
USO1	0.491	0.400	0.369	0.355	0.375	0.370	0.514	0.584	0.485	0.560	0.559	0.590	—	
USO2	0.424	0.388	0.478	0.268	0.325	0.390	0.728	0.763	0.706	0.710	0.481	0.573	0.684	—

Tabla 12. Continuación matriz de correlación de Pearson por variable observable.

Fuente: Elaboración propia



Análisis SEM

En un modelo de ecuaciones estructurales se busca que el modelo esté sobreestimado ($g.l > 0$), esto con el objetivo de tener más información en la matriz de datos que el número de parámetros a estimar. Tal como se puede observar en la Tabla 13, el modelo base se encuentra sobreestimado con 346 grados de libertad, por lo tanto, el modelo está identificado.

	AIC	BIC	n	Contraste de referencia		
				χ^2	gl	p
Modelo Base	25573.292	26046.042	406	894.062	346	< .001

Tabla 13. Ajuste del modelo Base

Fuente: Obtenido de Jasp

Dado que para esta investigación se utilizó un cuestionario basado en una escala Likert de 7 categorías, de acuerdo con (Finney & DiStefano, 2006) se considerarán los datos como continuos por naturaleza, con distribución normal y se empleará el método de máxima verosimilitud (MV).

Modelo Base

Por los resultados obtenidos anteriormente, se evidencia que la base de datos es adecuada para realizar el análisis SEM. Por lo que se utiliza el programa Jasp, a través del paquete Lavaan, que permite realizar modelos de ecuaciones estructurales. A continuación, se mostrará el modelo aplicado a los datos recolectados, por medio del diagrama de sendero y los resultados de la regresión.

Primeramente, en la Figura 26 se plasma el diagrama de senderos que permite visualizar por las flechas negras las relaciones de causalidad entre variables observables y latentes del modelo, mientras que las flechas en color gris indican las correlaciones existentes en el modelo.

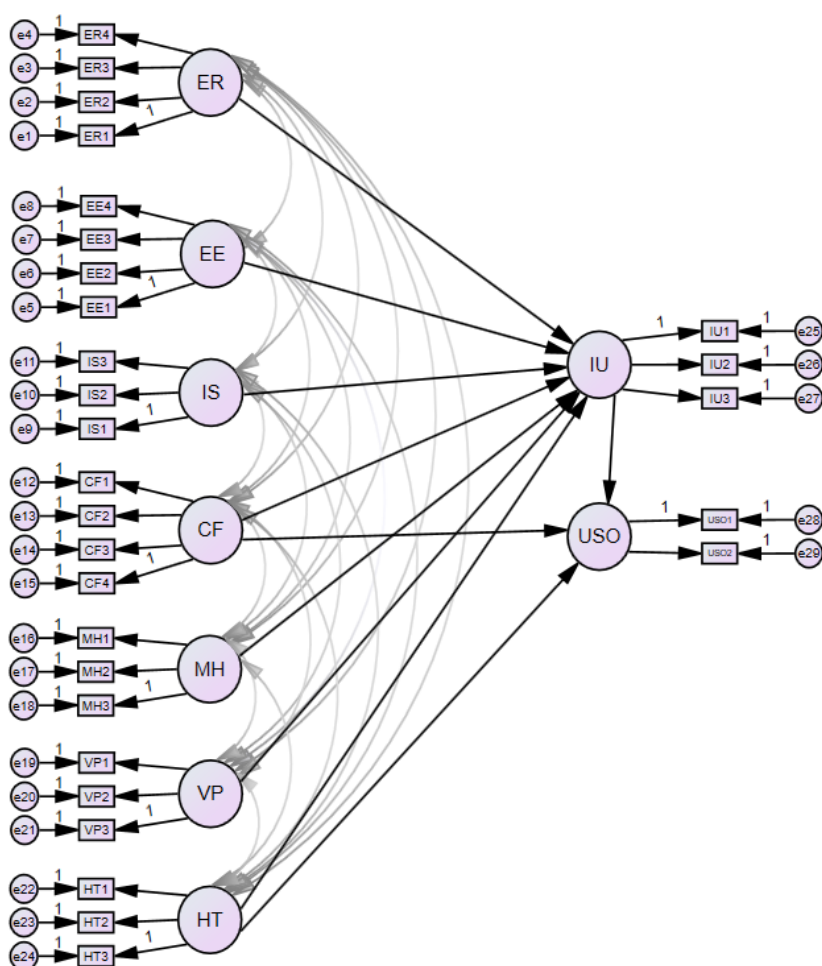


Figura 26. Diagrama de senderos Modelo Base

Fuente: Obtenido de SPSS AMOS

La columna "Estimar" indica el cambio en la variable dependiente por cada unidad de cambio en la variable independiente. Siguiendo esta lógica, mientras mayor sea el valor del coeficiente más afectará a la variable dependiente, dando un mayor nivel de importancia a la variable independiente que acompañe al coeficiente mayor. El "Error Típico" refleja la precisión de esta estimación. Para los valores "p" se estableció un umbral de 0.05, considerando estadísticamente significativas las relaciones con valores inferiores a este límite.



Resultado	Predictor	Estimar	Error Típico	valor Z	p	95% Intervalo de Confianza	
						Inferior	Superior
intención	rendimiento	0.225	0.086	2.616	0.009	0.056	0.393
	esfuerzo	-0.272	0.163	-1.669	0.095	-0.590	0.047
	social	0.102	0.049	2.065	0.039	0.005	0.198
	facilitadora	0.283	0.189	1.493	0.136	-0.088	0.654
	motivación	0.121	0.069	1.766	0.077	-0.013	0.255
	valor	0.063	0.065	0.962	0.336	-0.065	0.191
	habito	0.378	0.046	8.206	< .001	0.288	0.468
uso	facilitadora	0.234	0.053	4.426	< .001	0.130	0.337
	habito	0.527	0.049	10.838	< .001	0.431	0.622
	intención	0.239	0.056	4.300	< .001	0.130	0.348

Tabla 14. Coeficientes de regresión y significancia de cada variable latente

Fuente: Obtenido de Jasp

Variable Intención de Uso

Del “valor-p” se puede observar que las únicas variables que tienen significancia en la predicción de la variable dependiente de la intención de uso y por lo mismo tienen un impacto sobre esta son la expectativa del rendimiento ($p = 0.009$), la influencia social ($p = 0.039$) y el hábito ($p < 0.001$).

Mientras que las variables que no resultan significativas son la expectativa del esfuerzo ($p = 0.095$), las condiciones facilitadoras ($p = 0.136$), la motivación hedónica ($p = 0.077$) y el valor-precio ($p = 0.336$). Como estas variables indican que no existe una relación entre este factor y la variable dependiente, se decide eliminarlas del modelo.

Variable Conducta de Uso

Del “valor-p” se puede observar que todas las variables tienen significancia en la predicción de la variable dependiente de la conducta de uso y por lo mismo tienen un impacto sobre esta ($p < 0.001$).



A continuación, en la Tabla 15 se muestran los indicadores utilizados para evaluar el ajuste del modelo y los resultados obtenidos para el primer modelo base.

Ajuste	Índice	Valor	Criterio
Absoluto	Chi-cuadrado (χ^2)	$p < 0.001$	$p < 0.05$ buen ajuste
	RMSEA	0.062	< 0.05 buen ajuste $0.05 < x < 0.08$ aceptable
	GFI	0.859	> 0.9 buen ajuste $0.8 < x < 0.9$ aceptable
Incremental	NFI	0.9	> 0.9 buen ajuste $0.8 < x < 0.9$ aceptable
	CFI	0.938	
	TLI	0.925	
Parsimonia	PNFI	0.767	> 0.5 buen ajuste

Tabla 15. Indicadores de ajuste del modelo base

Fuente: Obtenido de Jasp

Como se puede apreciar, para un ajuste absoluto se obtuvieron valores para **chi-cuadrado**, **RMSEA** y **GFI** que se encuentran dentro de rangos aceptables, lo que sugiere que el modelo tiene un ajuste razonablemente bueno con una cantidad aceptable de error de aproximación. En cuanto a los índices de ajuste incremental, el **NFI**, **CFI** y **TLI** superan el umbral de 0.90, indicando un buen ajuste confirmando un ajuste satisfactorio del modelo. El índice de parsimonia **PNFI** indica que el modelo mantiene un buen equilibrio entre ajuste y parsimonia, sugiere un buen ajuste considerando la complejidad del modelo.

De igual manera, el modelo necesita ser modificado ya que existen relaciones que no son estadísticamente significativas, por lo que estos valores del ajuste de bondad pueden sufrir variaciones.

Modelo Modificado

A partir de las estimaciones preliminares del modelo UTAUT 2, se llevaron a cabo los ajustes para optimizar su relevancia estadística. Durante este proceso, se eliminaron las



variables que no mostraron significancia estadística, y el modelo fue reestimado incluyendo únicamente las relaciones que resultaron ser estadísticamente significativas. A continuación, se presenta el diagrama de senderos y los resultados obtenidos tras aplicar este enfoque:




Figura 27. Diagrama de senderos Modelo Modificado

Fuente: Obtenido de SPSS AMOS

Resultado	Predictor	Estimar	Error Típico	valor Z	p	95% Intervalo de Confianza	
						Inferior	Superior
intención	rendimiento	0.320	0.057	5.587	< .001	0.208	0.432
	social	0.159	0.043	3.711	< .001	0.075	0.243
	habito	0.446	0.050	9.007	< .001	0.349	0.543
uso	facilitadora	0.270	0.066	4.104	< .001	0.141	0.399
	habito	0.601	0.056	10.661	< .001	0.490	0.711
	intención	0.263	0.057	4.603	< .001	0.151	0.375

Tabla 16. Coeficientes de regresión y significancia modelo modificado

Fuente: Obtenido de Jasp



En la Tabla 16 se observa que se han excluido las variables que no presentaban significancia estadística. Al examinar los coeficientes de las relaciones que resultaron significativas, se destaca que la relación más robusta es entre el Hábito y la Conducta de uso, con un coeficiente de 0.601. Por otro lado, la relación más débil es la que existe entre la Influencia social y la Intención de uso, con un coeficiente de 0.159. En todos los casos, las estimaciones son positivas, lo que sugiere que a medida que los valores de las variables independientes aumentan, también lo hace la variable dependiente correspondiente.

Ajuste	Índice	Valor	Criterio
Absoluto	Chi-cuadrado (χ^2)	$p < 0.001$	$p < 0.05$ buen ajuste
	RMSEA	0.080	< 0.05 buen ajuste $0.05 < x < 0.08$ aceptable
	GFI	0.964	> 0.9 buen ajuste $0.8 < x < 0.9$ aceptable
Incremental	NFI	0.912	> 0.9 buen ajuste $0.8 < x < 0.9$ aceptable
	CFI	0.935	
	TLI	0.920	
Parsimonia	PNFI	0.747	> 0.5 buen ajuste

Tabla 17. Indicadores de ajuste del modelo modificado

Fuente: Obtenido de Jasp

Al comparar los indicadores del modelo base y el modificado, se puede notar una leve mejora para el ajuste absoluto en los valores del **GFI** dando como resultado ahora un buen ajuste del modelo. Para el valor de **RMSEA** aumentó de 0.062 a 0.08, conservándose aún dentro del rango aceptable. Para el ajuste incremental, el valor de **NFI** aumentó pasando a tener un buen ajuste. Los demás indicadores variaron marginalmente, lo que no provoca cambios en la interpretación. Se concluye que la modificación logró aumentar la relevancia estadística del modelo estudiado.

Análisis moderadores

Una vez que se ajustó el modelo eliminando las relaciones no significativas entre las variables, se procedió a realizar un análisis de moderación de acuerdo con las hipótesis



planteadas anteriormente, ya que no todas las variables son moderadas por los mismos factores. Este análisis no se había realizado previamente porque solo afecta a las relaciones que son estadísticamente significativas, por lo que era esencial identificar primero cuáles de estas relaciones tenían significancia. Es relevante destacar que el análisis de moderación influye en el valor y/o la dirección de las relaciones existentes, pero no establece la existencia de dichas relaciones. Para facilitar la interpretación de los resultados, se llevó a cabo el análisis de moderación de manera separada para cada variable: edad, género y experiencia.

EDAD

Resultado	Predictor	Estimar	Error Típico	valor Z	p	95% Intervalo de Confianza	
						Inferior	Superior
facilitadora	edad	-0.017	0.010	-1.662	0.096	-0.037	0.003
habito	edad	-5.886×10 ⁻⁴	0.014	-0.044	0.965	-0.027	0.026
rendimiento	edad	-0.002	0.012	-0.137	0.891	-0.025	0.021
social	edad	0.013	0.015	0.848	0.396	-0.017	0.042
intención	rendimiento	0.302	0.047	6.376	< .001	0.209	0.395
	social	0.190	0.033	5.734	< .001	0.125	0.254
	habito	0.458	0.042	10.829	< .001	0.375	0.541
uso	facilitadora	0.238	0.054	4.409	< .001	0.132	0.344
	habito	0.581	0.051	11.505	< .001	0.482	0.680
	intención	0.314	0.055	5.671	< .001	0.206	0.423

Tabla 18. Coeficientes de regresión y significancia moderador Edad

Fuente: Obtenido de Jasp

El análisis de los resultados presentados en la Tabla 18 revela que la variable moderadora de la Edad no ejerce una influencia estadísticamente significativa en las relaciones entre las variables del modelo propuesto. Específicamente, no se observa un efecto moderador de la edad en la forma en que estas variables latentes impactan tanto la intención de uso como la conducta de uso de las tecnologías en cuestión.

Esta ausencia de efecto moderador sugiere que, independientemente de su edad, los consumidores tienden a percibir de manera similar las condiciones facilitadoras, el hábito, la



expectativa del rendimiento y la influencia social como variables que afecten a su intención de utilizar estas tecnologías. Una posible explicación para este hallazgo radica en la composición demográfica de la muestra estudiada, la cual se centró principalmente en un público joven, resultando en una concentración de participantes dentro de un rango etario relativamente homogéneo. Considerando estos resultados, se ha tomado la decisión de simplificar el modelo eliminando las relaciones moderadas por la Edad, dado que estas no demostraron tener una significancia estadística relevante para el estudio.

GÉNERO

Resultado	Predictor	Estimar	Error Típico	valor Z	p	95% Intervalo de Confianza	
						Inferior	Superior
habito	genero	-0.136	0.163	-0.834	0.404	-0.455	0.183
social	genero	0.040	0.180	0.221	0.825	-0.314	0.393
rendimiento intención	genero	-0.012	0.141	-0.083	0.934	-0.287	0.264
	rendimiento	0.302	0.047	6.375	< .001	0.209	0.395
	social	0.190	0.033	5.736	< .001	0.125	0.255
uso	habito	0.458	0.042	10.829	< .001	0.375	0.541
	facilitadora	0.239	0.054	4.426	< .001	0.133	0.345
	habito	0.581	0.051	11.506	< .001	0.482	0.680
	intención	0.314	0.055	5.667	< .001	0.205	0.423

Tabla 19. Coeficientes de regresión y significancia moderador Género

Fuente: Obtenido de Jasp

La evaluación de los datos expuestos en la Tabla 19 indica que, de manera similar a lo observado con la variable moderadora de la Edad, el Género no desempeña un papel moderador estadísticamente significativo en las interacciones entre las variables del modelo. Esta falta de efecto moderador por parte del Género sugiere una uniformidad en la percepción de los consumidores, independientemente de su identidad de género. Específicamente, no se observan diferencias significativas en cómo los distintos géneros perciben las condiciones facilitadoras, el hábito, las expectativas de rendimiento y la influencia social como factores que inciden en su disposición a adoptar las tecnologías en cuestión.



En conclusión, se determina que el género no actúa como variable moderadora en ninguna de las relaciones propuestas en el modelo por lo que se ha optado optimizar el modelo, eliminando las relaciones moderadas por el género, dado que estas carecen de relevancia estadística para los objetivos del estudio. Este ajuste implica que la evaluación de la intención y la conducta de uso de esta tecnología se realiza de manera homogénea, sin distinción de género entre los consumidores.

EXPERIENCIA

Resultado	Predictor	Estimar	Error Típico	valor Z	p	95% Intervalo de Confianza	
						Inferior	Superior
facilitadora	experiencia	0.807	0.136	5.953	< .001	0.542	1.073
	habito	1.092	0.172	6.340	< .001	0.755	1.430
	social	0.921	0.194	4.756	< .001	0.542	1.301
intención	rendimiento	0.280	0.050	5.647	< .001	0.183	0.377
	social	0.189	0.034	5.593	< .001	0.122	0.255
	habito	0.449	0.043	10.466	< .001	0.365	0.533
uso	experiencia	0.230	0.137	1.686	0.092	-0.037	0.498
	facilitadora	0.279	0.057	4.927	< .001	0.168	0.390
	habito	0.575	0.051	11.364	< .001	0.476	0.675
	intención	0.323	0.055	5.842	< .001	0.214	0.431

Tabla 20. Coeficientes de regresión y significancia moderador Experiencia

Fuente: Obtenido de Jasp

En contraste con los moderadores previamente analizados, la experiencia emerge como un factor de considerable relevancia en la moderación de ciertas variables del modelo. Específicamente, se ha observado que la experiencia ejerce una influencia significativa en la moderación de las condiciones facilitadoras, el hábito y la influencia social. Sin embargo, es importante notar que no se detectó un efecto moderador significativo de la experiencia en la relación entre la intención de uso y la conducta de uso efectiva. En síntesis, el análisis reveló tres relaciones significativamente moderadas por la experiencia: las condiciones facilitadoras, los hábitos y la influencia social. En consecuencia, se procedió a refinar el modelo, eliminando solo aquella relación que no mostró significancia estadística.

Modelo Final

Tras los ajustes de todos los moderadores, se avanzó hacia la construcción del modelo final, incorporando todos los hallazgos y análisis previos para una representación más precisa de las dinámicas observadas. A continuación, se presentan los resultados de este modelo final, donde se incorpora el moderador de la experiencia representado por las flechas de color azul que indican la influencia a las variables de influencia social, hábito y condiciones facilitadoras.




Figura 28. Diagrama de senderos Modelo Final

Fuente: Obtenido de SPSS AMOS

Resultado	Predictor	Estimar	Error Típico	valor Z	p	95% Intervalo de Confianza	
						Inferior	Superior
facilitadora	experiencia	0.808	0.136	5.959	< .001	0.542	1.074
habito	experiencia	1.104	0.172	6.422	< .001	0.767	1.441
social	experiencia	0.928	0.194	4.791	< .001	0.548	1.307
intención	rendimiento	0.303	0.047	6.396	< .001	0.210	0.396
	social	0.189	0.033	5.715	< .001	0.124	0.254
	habito	0.458	0.042	10.882	< .001	0.376	0.541
uso	facilitadora	0.280	0.057	4.956	< .001	0.169	0.391
	habito	0.584	0.051	11.482	< .001	0.484	0.683
	intención	0.312	0.055	5.652	< .001	0.204	0.420

Tabla 21. Coeficientes de regresión y significancia modelo final

Fuente: Obtenido de Jasp

La Tabla 21 logra representar todas las relaciones que han demostrado ser estadísticamente significativas en el modelo. Al observar las estimaciones, queda claro que todas las variables tienen un efecto positivo en la intención y la conducta de uso de la tecnología. Es importante destacar que la variable del Habito tiene un impacto más significativo en comparación con las demás variables, las cuales tienen un efecto menor pero aun así son relevantes. A continuación, se presenta los indicadores del ajuste de bondad que se obtuvieron para el modelo final.

Ajuste	Índice	Valor	Criterio
Absoluto	Chi-cuadrado (χ^2)	p < 0.001	p < 0.05 buen ajuste
	RMSEA	0.108	< 0.05 buen ajuste 0.05 < x < 0.08 aceptable
	GFI	0.953	> 0.9 buen ajuste 0.8 < x < 0.9 aceptable
Incremental	NFI	0.843	> 0.9 buen ajuste 0.8 < x < 0.9 aceptable
	CFI	0.866	
	TLI	0.842	
Parsimonia	PNFI	0.715	> 0.5 buen ajuste

Tabla 22. Indicadores de ajuste del modelo final

Fuente: Obtenido de Jasp



El análisis de los indicadores presentados en la Tabla 22 revela una proximidad general a los valores considerados óptimos, lo que sugiere que el modelo propuesto exhibe desviaciones mínimas y, en su conjunto, se ajusta de manera satisfactoria a los datos observados. Es relevante destacar que el índice **RMSEA** es el único que se sitúa fuera de los rangos convencionalmente aceptados. Sin embargo, los demás indicadores se mantienen dentro de los parámetros que denotan un ajuste entre bueno y aceptable. Esta observación nos permite inferir que la incorporación de las variables moderadoras no resultó en una mejora sustancial del modelo, en comparación con el modelo sin moderadores, aunque tampoco provocó un deterioro significativo en su capacidad explicativa.

La congruencia observada entre el modelo teórico y los datos empíricos respalda la robustez del enfoque de modelado empleado, sugiriendo una adecuada capacidad para explicar los fenómenos del estudio. Sin embargo, es fundamental reconocer que la perfección en el modelado es un ideal difícilmente alcanzable. Existe un margen de variabilidad no explicada que puede atribuirse a diversos factores no contemplados en el modelo actual.

Esta evaluación destaca la solidez general del modelo propuesto, los resultados obtenidos proporcionan una base sólida para futuras investigaciones y refinamientos del modelo, con el objetivo de mejorar su precisión y capacidad predictiva.

Finalmente, y a modo de síntesis, se genera la siguiente tabla resumen de las hipótesis.

Hipótesis	Resultado	Motivo
H1: La Expectativa del rendimiento (ER) influye en la Intención de uso (IU)	Aceptada	Demuestra significancia estadística.
H2: La Edad y el Género del individuo moderan la influencia de la Expectativa del rendimiento (ER) en la Intención de uso (IU)	Rechazada	No demuestran significancia estadística para esta variable.
H3: La Expectativa del esfuerzo (EE) influye en la Intención de uso (IU)	Rechazada	No demuestra significancia estadística.
H4: La Edad, el Género y la Experiencia del individuo moderan la influencia de la Expectativa del esfuerzo (EE) en la Intención de uso (IU)	Rechazada	La variable EE no demuestra significancia estadística en IU.
H5: La Influencia social (IS) influye en la Intención de uso (IU)	Aceptada	Demuestra significancia estadística.

H6: La Edad, el Género y la Experiencia del individuo moderan la Influencia social (IS) en la Intención de uso (IU)	Rechazada	Solo la experiencia demuestra significancia estadística.
H7: La Facilidad de condiciones (FC) influye en la Intención de uso (IU)	Rechazada	No demuestra significancia estadística.
H8: La Facilidad de condiciones (FC) influye en la Conducta de uso (USO)	Aceptada	Demuestra significancia estadística.
H9: La Edad, el Género y la Experiencia del individuo moderan la influencia de la Facilidad de condiciones (FC) en la Intención de uso (IU)	Rechazada	La variable FC no demuestra significancia estadística en IU.
H10: La Edad y la Experiencia del individuo moderan la influencia de la Facilidad de condiciones (FC) en la Conducta de uso (USO)	Rechazada	Solo la experiencia demuestra significancia estadística.
H11: La Motivación Hedónica (MH) influye en la Intención de uso (IU)	Rechazada	No demuestra significancia estadística.
H12: La Edad, el Género y la Experiencia del individuo moderan la influencia de la Motivación Hedónica (MH) en la Intención de uso (IU)	Rechazada	La variable MH no demuestra significancia estadística en IU
H13: El Valor – Precio (VP) influye en la Intención de uso (IU)	Rechazada	No demuestra significancia estadística.
H14: La Edad y el Género del individuo moderan la influencia del Valor – Precio (VP) en la Intención de uso (IU)	Rechazada	La variable VP no demuestra significancia estadística en IU
H15: El Hábito (HT) influye en la Intención de uso (IU)	Aceptada	Demuestra significancia estadística.
H16: El Hábito (HT) influye en la Conducta de uso (USO)	Aceptada	Demuestra significancia estadística.
H17: La Edad, el Género y la Experiencia del individuo moderan la influencia del Hábito (HT) en la Intención de uso (IU)	Rechazada	Solo la experiencia demuestra significancia estadística.
H18: La Edad, el Género y la Experiencia del individuo moderan la influencia del Hábito (HT) en la Conducta de uso (USO)	Rechazada	Solo la experiencia demuestra significancia estadística.
H19: La Intención de uso (IU) influye en la Conducta de uso (USO)	Aceptada	Demuestra significancia estadística.
H20: La Experiencia del individuo modera la influencia de la Intención de uso (IU) en la Conducta de uso (USO)	Rechazada	No demuestra significancia estadística para esta variable.

Tabla 23. Resultados de Hipótesis

Fuente: Obtenido de Jasp



Capítulo VII: Conclusiones generales

El objetivo general de esta investigación fue examinar y modelar los factores que influyen en el comportamiento de los consumidores de inteligencia artificial para la creación de contenido en redes sociales en Chile. Para abordar este propósito, se adoptó un enfoque teórico basado en el Modelo de Aceptación de Tecnología Unificada 2 (UTAUT2). En base a este, se desarrolló un modelo de investigación respaldado por la formulación de hipótesis que exploraban los diversos factores que influyen en el comportamiento de los consumidores en relación con la intención y la conducta de uso de esta tecnología, además de su relación entre ellas y sus moderadores. A través de análisis cualitativos y cuantitativos rigurosos, se comprendió la estructura de los datos recopilados y se validaron para poder construir un modelo sólido y estadísticamente significativo. Esta investigación persiguió responder a la pregunta central: ¿Cuáles son las variables que afectan o influyen en el uso de la inteligencia artificial para crear contenido en redes sociales en Chile?

Resultados

Los hallazgos de este estudio, tal como se puede visualizar en la Tabla 21, revelan que los factores que resultaron significativos sobre la Intención de Uso son la Expectativa de Rendimiento, la Influencia Social y el Hábito. Mientras que las Condiciones Facilitadoras, el Hábito y la Intención de Uso ejercen un impacto directo significativo en la Conducta de Uso de los consumidores. Es importante destacar que estos factores afectan de manera positiva el comportamiento de consumidores en el sentido de promover su intención y conducta de usar la IA.

Se entiende que la Expectativa de Rendimiento afecta positivamente la Intención de Uso porque los usuarios anticipan que la IA mejorará significativamente su eficiencia y efectividad en la creación de contenido para redes sociales. Esperan que la tecnología les permita producir contenido de mayor calidad, más rápido y con menos esfuerzo, lo que aumenta su disposición a adoptar y utilizar estas herramientas.

La Influencia Social tiene un impacto positivo en la Intención de Uso debido a la naturaleza interconectada de las redes sociales. Los consumidores resultan ser más propensos



a adoptar tecnologías de IA cuando ven que sus pares, influencers o competidores las están utilizando con éxito. La presión social y el deseo de mantenerse competitivos en un entorno digital en constante evolución impulsan la intención de usar estas herramientas.

Las Condiciones Facilitadoras afectan positivamente la Conducta de Uso porque proporcionan el entorno y los recursos necesarios para que los usuarios puedan utilizar efectivamente la IA en la creación de contenido. Esto puede incluir acceso a internet estable, software fácil de usar, soporte técnico, entre otros. Cuando estas condiciones están presentes, los usuarios encuentran menos barreras para el uso real de la tecnología, lo que aumenta la probabilidad de que la utilicen regularmente.

El Hábito influye positivamente en la Intención y en la Conducta de Uso porque representa la automatización del comportamiento. Una vez que los usuarios han integrado el uso de herramientas de IA en su rutina de creación de contenido, tienden a utilizarlas de manera casi automática, sin necesidad de una deliberación consciente cada vez. La familiaridad y la comodidad que se desarrollan con el uso regular de estas tecnologías refuerzan la intención de seguir utilizándolas en el futuro y en una conducta de uso más frecuente y consistente.

Mientras que la Intención de Uso afecta positivamente la Conducta de Uso porque representa la disposición y el plan consciente de un individuo para utilizar la tecnología. Cuando los usuarios tienen una fuerte intención de usar herramientas de IA para crear contenido, es más probable que traduzcan esa intención en acciones concretas, resultando en un uso real y continuo de la tecnología.

Moderadores

Dentro del análisis de los moderadores, se analizaron los 3 factores moderadores (Edad, Género y Experiencia), donde solamente la Experiencia resultó significativa para las variables de Condiciones Facilitadoras, Hábito e Influencia Social afectándolas positivamente. Estas relaciones pueden interpretarse de la siguiente manera:



Los consumidores con menor Experiencia en el uso de inteligencia artificial tienden a otorgar mayor importancia a las opiniones y recomendaciones de su entorno social. Esto se atribuye a su necesidad de orientación y apoyo debido a su limitado conocimiento en el manejo de estas herramientas tecnológicas.

Por otra parte, los consumidores ya sean más o menos experimentados muestran una mayor valoración de las condiciones que facilitan su interacción con la tecnología. Esta preferencia se debe a su familiaridad con las nuevas tecnologías, que les permite identificar con mayor precisión los requisitos y potenciales obstáculos en su uso. Como resultado, estos usuarios asignan un mayor peso a los factores que optimizan su experiencia tecnológica en términos de eficiencia y efectividad.

Adicionalmente, la Experiencia influye directamente en la formación del Hábito. Es lógico suponer que un usuario con mayor experiencia en el uso de estas tecnologías habrá desarrollado patrones de comportamiento más arraigados, reflejándose en una conducta habitual más pronunciada.

Ajuste de bondad

El análisis de los resultados revela un panorama alentador respecto al modelo final propuesto para explicar la adopción y uso de la inteligencia artificial en la creación de contenido para redes sociales. La mayoría de los indicadores se alinean con los valores considerados óptimos, lo que sugiere un ajuste satisfactorio entre el modelo teórico y los datos empíricos observados. Esta congruencia respalda la robustez del enfoque de modelado empleado, indicando una adecuada capacidad explicativa de los fenómenos estudiados.

No obstante, es importante señalar que el índice RMSEA se sitúa fuera de los rangos convencionalmente aceptados, lo que apunta a áreas de mejora potencial en el modelo, por ejemplo utilizar un método de recolección que no sea por conveniencia así la muestra recolectada puede ser más representativa de la población total. Asimismo, la incorporación de variables moderadoras no resultó en una mejora sustancial del modelo, aunque tampoco



provocó un deterioro significativo en su capacidad explicativa. Esto sugiere que el papel de estas variables podría requerir una investigación más profunda en futuros estudios.

A pesar de estas limitaciones, el modelo demuestra una solidez general que proporciona una base firme para futuras investigaciones. Es fundamental reconocer que la perfección en el modelado estadístico es un ideal difícilmente alcanzable, y siempre existirá un margen de variabilidad no explicada atribuible a factores no contemplados en el modelo actual. Esta apreciación realista de las limitaciones inherentes al proceso de modelado refuerza la validez de los hallazgos y abre caminos para futuros refinamientos.

En última instancia, los resultados obtenidos no solo validan el enfoque utilizado, sino que también establecen un punto de partida sólido para continuar explorando y mejorando nuestra comprensión de cómo los usuarios adoptan y utilizan la inteligencia artificial en el contexto de la creación de contenido para redes sociales. Este modelo sienta las bases para futuros avances incrementales en el campo, permitiendo un refinamiento continuo de nuestra capacidad para predecir y explicar estos comportamientos tecnológicos emergentes.

Recomendaciones

En vista de los hallazgos obtenidos a través del análisis del modelo UTAUT2 adaptado para la adopción y uso de inteligencia artificial en la creación de contenido para redes sociales, es posible formular una serie de recomendaciones tanto para los desarrolladores de tecnologías de IA como para los usuarios finales de estas herramientas.

En primer lugar, es imperativo que los desarrolladores de herramientas de IA centren sus esfuerzos en mejorar el rendimiento percibido de sus productos. Dado que la expectativa de rendimiento se ha identificado como un factor significativo en la intención de uso, las innovaciones tecnológicas futuras deberían enfocarse en demostrar de manera tangible cómo la IA puede incrementar la eficiencia y la calidad en la creación de contenido. Esto podría lograrse mediante la implementación de funcionalidades que no solo ahorren tiempo, sino que también



mejoren visiblemente la calidad del contenido producido, además de la implementación de estrategias de marketing con el fin de incentivar y dar a conocer estas herramientas mediante la demostración de su rendimiento y utilidad.

Asimismo, considerando la importancia del hábito en la intención y conducta de uso, se recomienda que los desarrolladores presten especial atención al diseño de interfaces intuitivas y flujos de trabajo que se integren sin dificultad en las rutinas existentes de creación de contenido. La facilidad de incorporación de estas herramientas en el uso diario aumentará la probabilidad de que su utilización se convierta en un hábito arraigado.

Un aspecto crucial que no se debe soslayar es la provisión de condiciones facilitadoras adecuadas. Los desarrolladores deben asegurarse de que exista un entorno propicio para el uso efectivo de sus herramientas. Esto implica no solo el desarrollo de software robusto y fácil de usar, sino también la provisión de recursos de soporte comprensivos. Una de las principales dificultades es la resistencia al cambio y “se produce tanto en el ámbito organizacional como personal, pudiendo estar ligada a la personalidad, al sistema social y al modo de implementación de cambio; adoptando diversas formas.” (López Duque, Restrepo de Ocampo, & López Velásquez, 2013). Se recomienda la implementación de información clara y accesible, tutoriales en video, y un servicio de atención al cliente eficiente. Estas condiciones facilitadoras son fundamentales para superar las barreras iniciales de adopción y fomentar un uso sostenido de la tecnología.

Por otra parte, teniendo en cuenta el papel moderador de la experiencia, se sugiere la implementación de sistemas que se adapten al nivel de experticia del usuario. Esto podría materializarse en la forma de tutoriales más detallados para principiantes y funcionalidades avanzadas para usuarios experimentados, permitiendo así una curva de aprendizaje más suave y una adopción más efectiva de la tecnología.

En cuanto a las empresas, influencers y creadores de contenido, se recomienda una adopción estratégica de las herramientas de IA. Es crucial que estos actores evalúen



cuidadosamente cómo la IA puede mejorar específicamente su rendimiento en la creación de contenido, identificando las áreas donde puede tener el mayor impacto. La integración de estas herramientas en las rutinas diarias de creación de contenido debería realizarse de manera consciente y consistente, permitiendo que su uso se convierta en un hábito productivo. “Es necesario adecuar la educación al fortalecimiento de la inteligencia artificial como factor esencial de la revolución 4.0” (Rodríguez-Alegre, Trujillo-Valdiviezo, Egusquiza-Rodríguez, López-Padilla, & Rosario-del-Pilar, 2021).

Considerando la importancia de la influencia social en la intención de uso, se aconseja a las empresas e influencers compartir abiertamente su experiencia con las herramientas de IA y los beneficios obtenidos. Esta práctica puede tener un efecto positivo en la adopción de tecnologías similares dentro de sus redes de influencia.

Es importante destacar que la inversión en aprendizaje y dominio de las herramientas de IA es fundamental. La experiencia ha demostrado ser un moderador significativo, por lo que cuanto más familiarizados estén los usuarios con la tecnología, más eficaz será su utilización. En este sentido, la participación en comunidades o grupos donde se puedan compartir experiencias y aprender de otros usuarios de IA puede acelerar la curva de aprendizaje y proporcionar valiosas perspectivas sobre las mejores prácticas. Como también, que los usuarios aprovechen plenamente las condiciones facilitadoras proporcionadas por los desarrolladores, esto implica utilizar activamente los recursos de soporte disponibles, participar en programas de capacitación cuando estén disponibles, y no dudar en buscar asistencia cuando sea necesario. La plena utilización de estas condiciones facilitadoras puede marcar la diferencia entre una adopción exitosa y una frustrada.

Finalmente, se recomienda a los usuarios mantener un equilibrio entre la automatización ofrecida por la IA y la autenticidad de su contenido. Si bien la IA puede mejorar significativamente la eficiencia en la creación de contenido, es crucial que los creadores mantengan su voz y estilo únicos, ya que la autenticidad sigue siendo un factor determinante en el éxito en las redes sociales.



Futuras investigaciones

Las recomendaciones para futuras investigaciones son esenciales para expandir y profundizar nuestro entendimiento sobre la adopción y uso de la inteligencia artificial en la creación de contenido para redes sociales. Basándonos en los resultados obtenidos y las limitaciones identificadas en el presente estudio, se proponen las siguientes líneas de investigación:

En primer lugar, es fundamental abordar el sesgo de la muestra observado en este estudio. La predominancia de un público joven en la muestra actual limita la generalización de los resultados a otros grupos etarios. Por lo tanto, se recomienda realizar investigaciones que incluyan una distribución demográfica más amplia y representativa. Esto podría permitir comprender la influencia de este factor moderador en la adopción y uso de la IA para la creación de contenido entre diferentes grupos de edad, desde adolescentes hasta adultos mayores.

Asimismo, se sugiere extender la investigación hacia otros contextos y disciplinas. Mientras que este estudio se centró en la creación de contenido para redes sociales, sería valioso explorar cómo el modelo se aplica en otros ámbitos de la comunicación digital, como el periodismo, el marketing de contenidos, o la educación en línea. Esto proporcionaría una comprensión más holística de cómo la IA está transformando diversos aspectos de la comunicación y la producción de contenido en la era digital.

Otra área prometedora para futuras investigaciones es la aplicación del modelo a diversos sectores socioeconómicos. Es posible que los factores que influyen en la adopción y uso de la IA varíen significativamente entre diferentes niveles socioeconómicos debido a disparidades en el acceso a la tecnología, la alfabetización digital, y los recursos disponibles. Un estudio comparativo entre estos sectores podría revelar resultados valiosos sobre la brecha digital y cómo abordarla en el contexto de las tecnologías de IA.



Se recomienda también llevar a cabo estudios longitudinales para examinar la implementación a largo plazo de las estrategias de adopción de IA. Mientras que el presente estudio ofrece una instantánea del fenómeno, un enfoque longitudinal permitiría observar cómo evolucionan los patrones de uso y adopción a lo largo del tiempo. Esto sería particularmente valioso para entender cómo se forman y mantienen los hábitos de uso, y cómo las percepciones y actitudes hacia la IA cambian con la experiencia prolongada.

Adicionalmente, se sugiere explorar más a fondo el papel de nuevas variables moderadoras. Aunque el presente estudio consideró solamente la experiencia como moderador significativo, futuras investigaciones podrían profundizar en cómo otros moderadores, influyen en las relaciones entre los constructos principales del modelo en el contexto específico de la IA para la creación de contenido.

Por último, se recomienda realizar estudios comparativos entre diferentes plataformas de redes sociales. Es posible que los factores que influyen en la adopción y uso de la IA varíen dependiendo de las características específicas de cada plataforma (por ejemplo, Instagram vs. LinkedIn). Un análisis comparativo podría proporcionar resultados valiosos para el desarrollo de herramientas de IA más especializadas y efectivas para cada plataforma.

Estas líneas de investigación propuestas no solo abordarían las limitaciones del presente estudio, sino que también expandirían significativamente nuestra comprensión de la adopción y uso de la IA en la creación de contenido digital. Los resultados de estas investigaciones futuras podrían tener implicaciones importantes para desarrolladores de tecnología, creadores de contenido, y formuladores de políticas en el ámbito de la comunicación digital y la inteligencia artificial.



Referencias

- Ain, N., Kaur, K., & Waheed, M. (2016). The influence of learning value on learning management system use: An extension of UTAUT2. *Information Development, 32*(5), 1306-1321.
- Ajzen, I., & Fishbein, M. (1980). Understanding Attitudes and Predicting Social Behavior.
- Ajzen, I., & Fishbein, M. A. (1975). Belief, attitude, intention and behaviour: An introduction to theory and research. *Reading, MA: Addison-Wesley.*
- Al-Adwan, A. S., & Al-Debei, M. M. (2024). The determinants of Gen Z's metaverse adoption decisions in higher education: Integrating UTAUT2 with personal innovativeness in IT. *Education and Information Technologies 29*, 7413–7445.
- Alalwan, A., Dwivedi, Y., Rana, N. P., & Williams, M. (2016). Consumer adoption of mobile banking in Jordan: Examining the role of usefulness, ease of use, perceived risk and self-efficacy. *Journal of Enterprise Information Management, 118-139.*
- Alcántara, K. E., Nava, M. D., & Silva, C. (2022). Propiedades Psicométricas del Cuestionario de Sobreingesta (OQ) en Universitarios del Valle de México. *Acta De Investigación Psicológica, 12*(1), DOI: <https://doi.org/10.22201/fpsi.20074719e.2022.1.418>.
- Alghamdi AM, A. D. (2022). University students' behavioral intention and gender differences toward the acceptance of shifting regular field training courses to e-training courses. *Educ Inf Technol (Dordr).*, 451–468.
- Alomary, A., & Woollard, J. (2015). How Is Technology Accepted by Users? A Review of Technology Acceptance Models and Theories. *The IRES 17th International Conference.*
- Alonso, A. D., & Jara, E. A. (2016). Visión por computadora: identificación, clasificación y seguimiento de objetos. *FPUNE Scientific, 10*).
- Atenas, F., Sanhueza, F., & Valenzuela, C. (s.f.). Redes Neuronales Adversarias Convolucionales para generación de imágenes.
- Ato, M., & Vallejo, G. (2011). Los efectos de terceras variables en la investigación psicológica. *Anales de Psicología / Annals of Psychology, 27*(2), 550-561.
- Bentler, P. M., & Bonett, D. G. (1980). Significance tests and goodness of fit in the analysis of covariance structures. *Psychological bulletin, 88*(3), 588.
- Brown, S. A., Venkatesh, V., & Bala, H. (2006). Household Technology Use: Integrating Household Life Cycle and the Model of Adoption of Technology in Households. *The Information Society (22:4)*, 205-218.
- Browne, M. W., & Cudeck, R. (1993). Alternative ways of assessing model fit. *Sage focus editions, 154*, 136-136.
- Byrne, B. M. (2016). Structural Equation Modeling with AMOS: Basic Concepts, Applications, and Programming, 2nd edition.
- Calva-Cabrera, K. D., León-Alberca, T., & Arpi-Fernández, C. G. (2024). Capítulo 1. Inteligencia Artificial en las redes sociales digitales. *Espejo de Monografías de Comunicación Social*, <https://api.semanticscholar.org/CorpusID:269827595>.
- Cardador, P. F. (2015). Análisis de los factores de influencia en la adopción de herramientas colaborativas basadas en software social. Aplicación a entornos empresariales. *Tesis Doctoral. Universidad Politécnica de Madrid.*



- Carr, C. T., & Hayes, R. A. (2015). Social Media: Defining, Developing, and Divining. *Atlantic Journal of Communication*, 23(1), 46-65.
- Centeno, T. B., Ferreira, C. C., Inga, J. G., Vélez, A., Huacho, R., Vidal, O. D., . . . Tomazello-Filho, M. (2023). Herramientas de corte para optimizar parámetros de clasificación de especies maderables con redes neuronales convolucionales. *Revista de Biología Tropical*, <https://api.semanticscholar.org/CorpusID:262180911>.
- Chawla, D., & Joshi, H. (2019). Consumer attitude and intention to adopt mobile wallet in India – An empirical study. *International Journal of Bank Marketing* 37.
- Chen, H. a.-K.-W. (2014). Exploring the commercial value of social networks: Enhancing consumers' brand experience through Facebook pages. *Journal of Enterprise Information Management*.
- Chew, H. S., Achananuparp, P., Dalakoti, M., Chew, N. W., Chin, Y. H., Gao, Y., . . . Ngiam, K. Y. (2024). Public acceptance of using artificial intelligence-assisted weight management apps in high-income southeast Asian adults with overweight and obesity: a cross-sectional study. *Frontiers in Nutrition*.
- Civelek, M. E. (2018). Essentials of Structural Equation Modeling.
- Corredera, J. R. (2023). Inteligencia artificial generativa . *Anales de la Real Academia de Doctores de España. Volumen 8, número 3*, 475-489.
- Cupani, M. (2012). Análisis de Ecuaciones Estructurales: conceptos, etapas de desarrollo y un ejemplo de aplicación. *Revista Tesis*, 2, 186-199.
- Davenport, T. H., & Ronanki, R. (2018). Artificial Intelligence por the Real World. *Harvard Business Review*, 115.
- Davis, F. D. (1989). Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. *MIS Quarterly*, 319-339.
- Díaz, M. A. (2022). ESTUDIO DE LOS FACTORES QUE AFECTAN LA ACEPTACIÓN Y USO DE LAS TECNOLOGÍAS DE LA INFORMACIÓN EN LOS ESTUDIANTES DE INGENIERÍA CIVIL INDUSTRIAL DE LA UNIVERSIDAD FEDERICO SANTA MARÍA. *Memoria para optar al título de Ingeniero Civil Industrial*.
- Díaz-Ramírez, J. (2021). Aprendizaje Automático y Aprendizaje Profundo. . *Revista chilena de ingeniería*, 180-181.
- Dodds, W. B., Monroe, K., & Grewal, D. (1991). Effects of Price, Brand, and Store Information on Buyers' Product Evaluations. *Journal of Marketing Research* 28(3).
- Ebersbach, A., Glaser, M., & Heigl, R. (2008). Social web. *Konstanz: UVK Verlagsgesellschaft mbH*.
- El-Masri, M., & Tarhini, A. (2017). Factors affecting the adoption of e-learning systems in Qatar and USA: Extending the Unified Theory of Acceptance and Use of Technology 2 (UTAUT2). *Cultural and Regional Perspectives, Volume 65*, 743–763.
- Emon, M. M., Hassan, F., Nahid, M. H., & Rattanawiboonsom, V. (2023). Predicting Adoption Intention of Artificial Intelligence. *AJSE, vol. 22, no. 2*, 189 - 199.
- F. Muñoz-Leiva, S. C.-C.-C. (2017). Determinants of intention to use the mobile banking apps: An extension of the classic TAM model. *Spanish Journal of Marketing - ESIC, Volume 21, Issue 1*, 25-38.
- Fausser, S., Wiedenhofer, J., & Lorenz, M. (2011). "Touchpoint social web": an explorative study about using the social web for influencing high involvement purchase decisions. *Problems and Perspectives in Management, Volume 9, Issue 1*.



- Finney, S., & DiStefano, C. (2006). Non-normal and Categorical data in structural equation modeling. In G. R. Hancock & R. O. Mueller (Eds.), *Structural equation modeling: A second course*. Greenwich, Connecticut: Information Age Publishing, 269–314.
- Franganillo, J. (2023). La inteligencia artificial generativa y su impacto en la creación de contenidos mediáticos. *methaodos.revista de ciencias sociales*, 11(2).
- García, A. J., Pinargote, J. G., Baque, Y. N., & Montero, L. M. (2023). TÉCNICAS DE INTELIGENCIA ARTIFICIAL USADAS EN LA INVESTIGACIÓN DE MERCADOS. *Ciencia y Desarrollo. Universidad Alas Peruanas*.
- García, E. M., Pazmiño, A. M., Armijos, C. P., Sosa, G. L., & Reinoso, M. V. (2018). Inteligencia Artificial en la toma de decisiones gerenciales. *Dilemas contemporáneos: Educación, Política y Valores*.
- García-Vera, Y. S., Juca-Maldonado, F. X., & Torres-Gallegos, V. (2023). Automatización de procesos contables mediante Inteligencia Artificial: Oportunidades y desafíos para pequeños empresarios ecuatorianos. *Revista Transdisciplinaria de Estudios Sociales y Tecnológicos*, <https://api.semanticscholar.org/CorpusID:264087280>.
- Garmendia, A. (2018). Mediación y moderación. Dos formas distintas de interacción. *Obtenido de Blog del profesor Alfonso Garmendia: <https://garmendia.blogs.upv.es/mediacion-moderacion/>*.
- Garson, G. D. (2012). Testing statistical assumptions.
- George, D., & Mallery, P. (2003). *SPSS for Windows step by step: A simple guide and reference. 11.0 update (4thed.)*. Boston: Allyn & Bacon.
- Gómez-Diago, G. (2022). Perspectivas para abordar la inteligencia artificial en la enseñanza de periodismo. Una revisión de experiencias investigadoras y docentes. *Revista Latina de Comunicación Social*, (80), 29-46.
- González, Á. R., Estévez, C. J., Jaramillo, J. C., & Flores, E. R. (2023). Inteligencia artificial como estrategia de innovación en empresas de servicios: Una revisión bibliográfica. *Revista Publicando*, 74-82.
- Hair, J. F., Anderson, R. E., Tatham, R. L., & Black, W. C. (2004). Análisis multivariante 5a edición. *Pearson Prentice Hall*.
- Hair, J. F., Black, W., Babin, B. J., & Anderson, R. E. (2010). *Multivariate Data Analysis: A Global Perspective*.
- Hinkin, T. R. (1995). A review of scale development practices in the study of organizations. *Journal of Management*, Volume 21, Issue 5, 967-988.
- Holbrook, M. B., & Hirschman, E. C. (1982). The experiential aspects of consumption: Consumer fantasies, feelings, and fun. *Journal of Consumer Research*, 9(2), 132-140.
- Hooper, D., Coughlan, J., & Mullen, M. R. (2008). Structural Equation Modelling : Guidelines for Determining Model Fit. 53–60.
- Hootsuite. (2023). Social media trends 2023. *Hootsuite Inc*.
- Il Im, S. H. (2011). An international comparison of technology adoption: Testing the UTAUT model. *Information & Management*, Volume 48, Issue 1, 1-8.
- Ince, H., Imamoglu, S. Z., & Turkcan, H. (2016). *The Effect of Technological Innovation Capabilities and Absorptive Capacity on Firm Innovativeness: A Conceptual Framework*. Antalya, Turkia: 12th International Strategic Management Conference.
- Influency. (22 de Julio de 2024). *Estudio sobre influencers Latinoamérica 2024*. Obtenido de Influency: <https://lookerstudio.google.com/u/0/reporting/9e835db5-4ffd-47bd-a08b->



- b07a5d85329c/page/QmZOB?s=oHNMYFZOtgk
- Jackson, D. L. (2003). Revisiting Sample Size and Number of Parameter Estimates: Some Support for the N:q Hypothesis. *Structural Equation Modeling*, 10, 128-141.
- Jarrahi, M. H. (2018). Artificial intelligence and the future of work: Human-AI symbiosis in organizational decision making. *Business Horizons*, Volume 61, Issue 4, 577-586.
- Jorge Arenas-Gaitán, B. P.-P.-J. (2015). Elderly and internet banking: An application of UTAUT2. *The Journal of Internet Banking and Commerce* 20(1).
- Kaplan, A. M., & Haenlein, M. (2020). Rulers of the world, unite! The challenges and opportunities of artificial intelligence in the digital world order. *Business Horizons*, 63(1), 37-50.
- Kaplan, A., & Haenlein, M. (2010). Users of the World, Unite! The Challenges and Opportunities of Social Media. *Business Horizons* 53(1), 59-68.
- Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, 15-25.
- Kaplan, D. (2000). Structural equation modeling: Foundations and extensions. *Newbury Park, CA: Sage*.
- Kemp, S. (23 de febrero de 2024). *Digital 2024: Chile*. Obtenido de DataReportal: <https://datareportal.com/reports/digital-2024-chile>
- Kim, M. J., & Hall, C. M. (2019). A hedonic motivation model in virtual reality tourism: Comparing visitors and non-visitors. *International Journal of Information Management*, 236-249.
- Kline, R. B. (2005). Principles and Practice of Structural Equation Modeling (2nd ed.). *New York: Guilford*.
- Kline, R. B. (2011). Principles and practice of structural equation modeling, 3rd ed. *Guilford Press*.
- Laney, D. (2001). 3D Data Management: Controlling Data Volume, Velocity, and Variety. *META Group*, <http://blogs.gartner.com/doug-laney/files/2012/01/ad949-3D-Data-Management-Controlling-Data-Volume-Velocity-and-Variety.pdf>.
- López Duque, M. E., Restrepo de Ocampo, L. E., & López Velásquez, G. L. (2013). *Resistencia al cambio en organizaciones modernas*. Pereira, Colombia: Scientia Et Technica, vol. 18, núm. 1.
- Lowry, P. B., Gaskin, J. E., Twyman, N. W., Hammer, B., & Roberts, T. L. (2013). Taking "Fun and Games" Seriously: Proposing the Hedonic-Motivation System Adoption Model (HMSAM). *Journal of the Association for Information Systems*, 14(11).
- Lu, J., Yao, J. E., & Yu, C.-S. (2005). Personal innovativeness, social influences and adoption of wireless Internet services via mobile technology. *The Journal of Strategic Information Systems*, Volume 14, Issue 3, 245-268.
- MacCallum, R. C., Browne, M. W., & Sugawara, H. M. (1996). Power analysis and determination of sample size for covariance structure modeling. *Psychological Methods*, 1(2), 130-149.
- Mahto, A. K. (2023). ARTIFICIAL INTELLIGENCE FOR THE REAL WORLD. *International Research Journal of Modernization in Engineering Technology and Science*.
- Mcculloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous



- activity. *Bulletin of Mathematical Biophysics*, 115-133.
- McDonald, R. P., & Ho, M.-H. (2002). Principles and Practice in Reporting Statistical Equation Analyses. *Psychological Methods*, 7 (1), 64-82.
- McKinsey Global Institute. (2024). The state of AI in early 2024: Gen AI adoption spikes and starts to generate value. *McKinsey & Company McKinsey*, obtenido de: <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai#/>.
- Mehta, A., Morris, N. P., Swinnerton, B., & Homer, M. (2019). The Influence of Values on E-learning Adoption. *Computers & Education* 141.
- Miladinov, G. (5 de Abril de 2019). Los desafíos de la industria 4.0. *Presentación en la inauguración año académico del área de Escuelas de Ingeniería, Construcción y Recursos Naturales*. Santiago, Chile: Duoc UC.
- Moreno, E. G. (2001). *Automatización de procesos industriales*. Valencia: Alfaomega.
- Neira, F. G. (2020). Adopción y difusión de las tecnologías 4.0 a partir de la trayectoria innovativa y la escala de operación: el caso de Chile. *Revista de administración de empresas*, vol. 62, número 3, 21.
- Ngampornchai, A., & Adams, J. (2016). Students' acceptance and readiness for E-learning in Northeastern Thailand. *International Journal of Educational Technology in Higher Education*.
- Nikolopoulou, K., Gialamas, V., & Lavidas, K. (2020). Acceptance of mobile phone by university students for their studies: an investigation applying UTAUT2 model. *Education and Information Technologies* (25), 4139–4155.
- Nodd3r. (5 de Julio de 2022). *Netflix utiliza la inteligencia artificial para personalizar sus recomendaciones*. Obtenido de Nodd3r: <https://nodd3r.com/blog/netflix-utiliza-la-inteligencia-artificial-para-personalizar-sus-recomendaciones>
- Orellana, M. C. (2016). M-COMMERCE EN CHILE: APLICACIÓN DEL MODELO TAM. *Memoria para optar al título de Ingeniero Civil Industrial*.
- Palos-Sanchez, P., A. R.-M., & Saura, J. R. (2019). Modelos de Adopción de Tecnologías de la Información y Cloud Computing en las Organizaciones. *Información Tecnológica – Vol. 30 N° 3*, 3-12.
- Payam Hanafizadeh, M. B. (2014). Mobile-banking adoption by Iranian bank clients. *Telematics and Informatics*, 62-78.
- Poonpanich, N., & Buranasiri, J. (2022). Factors Affecting Baby Boomers' Attitudes towards the Acceptance of Mobile Network Providers' AI Chatbot. *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*.
- QuestionPro. (2024). *Tamaño de muestra*. Obtenido de QuestionPro: <https://www.questionpro.com/es/tamaño-de-la-muestra.html>
- RAE, F. (2022). *macrodatos e inteligencia de datos, alternativas a big data*. Madrid.
- Ramirez, V. (7 de Marzo de 2018). *House Of Cards: el éxito que Netflix creó gracias a la inteligencia artificial*. Obtenido de BigDataMagazine: <https://bigdatamagazine.es/house-of-cards-el-exito-que-netflix-creo-gracias-a-la-inteligencia-artificial#:~:text=Studies%2C%20Inteligencia%20Artificial-,House%20Of%20Cards%3A%20el%20%20C3%A9xito%20que%20Netflix,gracias%20a%20la%20inteligencia%20artificial>
- Rhemtulla, M., Brosseau-Liard, P., & Savalei, V. (2012). When can categorical variables be treated as continuous? A comparison of robust continuous and categorical SEM



- estimation methods under suboptimal conditions. *Psychological Methods*, 17(3), 354–373.
- Rodríguez-Alegre, Trujillo-Valdiviezo, L. R., Egusquiza-Rodríguez, G., López-Padilla, M. J., & Rosario-del-Pilar. (2021). *Revolución industrial 4.0: La brecha digital en Latinoamérica*. Venezuela: Revista Arbitrada Interdisciplinaria Koinonía.
- Rouhiainen, L. (2018). *Inteligencia artificial, 101 cosas que debes saber hoy sobre nuestro futuro*. España: Alienta.
- Roy-García, I., Rivas-Ruiz, R., Pérez-Rodríguez, M., & Palacios-Cruz, L. (2019). Correlación: no toda correlación implica causalidad. *Revista Alergia México*, 66(3), 354-360.
- Ruiz, M. A., Pardo, A., & Martín, R. S. (2010). MODELOS DE ECUACIONES ESTRUCTURALES. *Papeles del Psicólogo*, vol. 31, núm. 1, 34-45.
- Salancik, G. R., & Pfeffer, J. (1978). A Social Information Processing Approach to Job Attitudes and Task Design. *Administrative Science Quarterly*, Vol. 23, No. 2, 224-253.
- Salas, R. (2004). Redes Neuronales Artificiales. *Departamento de Computación*, 1-7.
- Salehi, H., & Burgueño, R. (2018). Emerging artificial intelligence methods in structural engineering. *Engineering Structures*, 170-189.
- Samuel, A. L. (1959). Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, vol. 3, no. 3, 210-229.
- Sanchez, J. A. (2002). Avances en robótica y visión por computador. *Univ de Castilla La Mancha*.
- Santos, J. C. (2019). Minería de Datos: Conceptos y Tendencias. *Inteligencia Artificial: Revista Iberoamericana de Inteligencia Artificial*, 11-18.
- Sanz, M. E. (21 de julio de 2023). *Cómo utilizar la Inteligencia Artificial (IA) para crear contenido en redes sociales de manera eficiente y personalizada*. Obtenido de linkedIn: <https://es.linkedin.com/pulse/%C3%B3mo-utilizar-la-inteligencia-artificial-ia-para-crear-diez-sanz>
- Schemmer, M., Hemmer, P., Nitsche, M., Kühn, N., & Vössing, M. (2022). *A Meta-Analysis of the Utility of Explainable Artificial Intelligence in Human-AI Decision-Making*. New York, NY, USA: Association for Computing Machinery.
- Schermelleh-Engel, K., Moosbrugger, H., & Müller, H. (2003). Evaluating the Fit of Structural Equation Models: Tests of Significance and Descriptive Goodness-of-Fit Measures. *Methods of Psychological Research Online*, 8(2), 23-74.
- Serrano, C. G. (2016). Modelos de ecuaciones estructurales, una manera eficiente de probar hipótesis de negocio. *SINNETIC*.
- Sharma, S., Kaushik, K., Sharma, R., & Chaturvedi, N. (2023). Explainable Artificial Intelligence (XAI). *IJFANS International Journal of Food and Nutritional Sciences*, doi: 10.48047/ijfans/v12/i1/271.
- Shen, S., X, K., Sotiriadis, M., & Wang, Y. (2022). Exploring the factors influencing the adoption and usage of Augmented Reality and Virtual Reality applications in tourism education within the context of COVID-19 pandemic. *Journal of Hospitality, Leisure, Sport & Tourism Education*.
- Shrestha, N. (2020). Detecting multicollinearity in regression analysis. *American Journal of Applied Mathematics and Statistics*, 8(2), 39-42.
- Smith, A., & Jones, B. (2022). The future of social media content: Emerging technologies and their impact. *Journal of digital marketing*, 15(3), 78-95.



- Statista Research Department. (5 de Marzo de 2024). *Las redes sociales en Chile - Datos estadísticos*. Obtenido de Statista: <https://es.statista.com/temas/10669/redes-sociales-en-chile/#topicOverview>
- Statista Research Department. (24 de mayo de 2024). *Tasa de penetración de las redes sociales en América Latina y el Caribe en febrero de 2024, por país*. Obtenido de Statista: <https://es.statista.com/estadisticas/1073796/alcance-redes-sociales-america-latina/>
- Torre, J. d. (2023). GANs: Fundamentos Teóricos y Aplicaciones.
- Vásquez, A. C., Huerta, H. V., Quispe, J. P., & Huayna, A. M. (2009). Procesamiento de lenguaje natural. *Rev. Investig. sist. inform.*, vol. 6, no. 2, 45-54.
- Venkatesh, V., & Davis, F. D. (2000). A Theoretical Extension of the Technology Acceptance Model: Four Longitudinal Field Studies. *Management Science* 46(2), 186-204.
- Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User Acceptance of Information Technology: Toward a Unified View. *MIS Quarterly* 27, no. 3, 425-478.
- Venkatesh, V., Thong, J. Y., & Xu, X. (2012). Consumer Acceptance and Use of Information Technology: Extending the Unified Theory of Acceptance and Use of Technology. *MIS Quarterly Vol. 36, No. 1*, 157-178.
- Virla, M. Q. (2010). Confiabilidad y coeficiente Alpha de Cronbach. *Telos*, vol. 12, núm. 2, 248-252.
- Wang, Y., & Zhang, W. (2023). Factors Influencing the Adoption of Generative AI for Art Designing Among Chinese Generation Z: A Structural Equation Modeling Approach. *IEEE Access, Volume 11*, 143272-143284.
- We Are Social; Meltwater. (Febrero de 2024). *Digital 2024, the essential guide to the latest connected behaviours*. Obtenido de DataReportal: <https://datareportal.com/reports/digital-2024-chile>
- Zúñiga, F., Poveda, D. A., & Mora, D. P. (2023). La importancia de la inteligencia artificial en las comunicaciones en los procesos marketing. *Vivat Academia. Revista de Comunicación*, <https://api.semanticscholar.org/CorpusID:259181481>.