

UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INDUSTRIAS

**EL IMPACTO DE LA INTELIGENCIA ARTIFICIAL EN LA PERSONALIZACIÓN DE
RECOMENDACIONES DE COMPRA EN MARCAS DE MODA: INFLUENCIA EN LA
PERCEPCIÓN DEL CONSUMIDOR**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERA CIVIL INDUSTRIAL

AUTORA

PÍA CATALINA URÍZAR CUEVAS

PROFESOR GUÍA

NOAH SILVA MORA

SANTIAGO, JUNIO, 2025



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): Memoria o trabajo de título; Tesis de Postgrado;

Título del trabajo: El impacto de la inteligencia artificial en la personalización de recomendaciones de compra en marcas de moda: Influencia en la percepción del consumidor

Nombre del candidato(a): Pía Catalina Urizar Cuevas

Carrera / Grado: Ingeniería Civil Industrial

Campus: Santiago Vitacura; **Departamento:** Industrias

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Noah Silva Mora, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL

El trabajo **NO contiene información que amerite confidencialidad** y puede ser publicado de inmediato en repositorio con acceso abierto.

El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (embargo) por:

6 meses; 12 meses; 2 años; 3 años; 5 años; 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 27/06/2025 ; Firma: 

Estudiante o Candidato(a):

Fecha: 27/06/2025 ; Firma: 

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

Resumen Ejecutivo

La presente investigación tiene como propósito analizar el impacto del uso de la Inteligencia Artificial (IA) en la personalización de recomendaciones de compra en marcas de moda, y su influencia en la percepción y decisiones de los consumidores en Chile. Se utilizó el modelo teórico Estímulo-Organismo-Respuesta (S-O-R), el cual permitió estudiar cómo variables como la interacción, la información, la accesibilidad y la personalización influyen en la experiencia de marca, y cómo esta, a su vez, afecta la preferencia de marca y la intención de recompra.

Se aplicó una metodología cuantitativa, basada en una encuesta estructurada a consumidores chilenos, cuyos datos fueron analizados mediante el software SPSS y AMOS. El modelo de investigación incluyó la validación de escalas mediante Alpha de Cronbach, análisis factorial confirmatorio (CFA) y el desarrollo de un Modelo de Ecuaciones Estructurales (SEM). Posteriormente, se realizaron ajustes al modelo original: se eliminó el constructo “Accesibilidad” por su bajo aporte teórico y estadístico, y se incorporaron correlaciones sugeridas entre variables, lo que mejoró significativamente los índices de ajuste del modelo final.

Los resultados muestran que los estímulos generados por la IA, particularmente la personalización y la información, influyen positivamente en la experiencia de marca. Esta, a su vez, actúa como mediadora clave entre los estímulos iniciales y las respuestas conductuales del consumidor, como la preferencia de marca y la intención de recompra. La interacción también mostró efectos positivos, fortaleciendo la percepción de cercanía con la marca.

Entre las recomendaciones, se plantea que las marcas de moda deben promover una experiencia personalizada que no solo sea técnicamente precisa, sino también emocionalmente significativa, cuidando aspectos como la confianza, la claridad de la información y el uso ético de los datos. El estudio aporta herramientas teóricas y prácticas para optimizar el uso de IA en el marketing digital en el contexto chileno.

Índice de contenido

Tabla de contenido

1.	Problema de investigación	6
2.	Objetivos	9
2.1	Objetivo General.....	9
2.2	Objetivos Específicos	9
3.	Marco Teórico	10
3.1	Publicidad digital y personalización de la publicidad	10
3.2	Beneficios del uso de Inteligencia artificial en la publicidad	18
3.3	Comportamiento del consumidor en la Publicidad Digital.....	23
3.4	Percepción del Consumidor ante la personalización mediante Inteligencia Artificial.....	31
3.5	Modelos de aceptación de nuevas tecnologías	36
3.5.1	Modelo de Aceptación Tecnológica (TAM)	36
3.5.2	Modelo Estímulo-Organismo-Respuesta (SOR).....	39
3.5.3	Validación de escalas mediante Alpha de Cronbach	41
3.6	Modelos de validación estadística.....	43
3.6.1	Análisis Factorial Confirmatorio (CFA)	43
3.6.2	Modelos de Ecuaciones Estructurales (SEM).....	44
4.	Modelo de investigación e hipótesis	46
4.1	Interacción	48
4.2	Información	49
4.3	Accesibilidad.....	50
4.4	Personalización.....	51
4.5	Experiencia de marca	52
4.6	Preferencia de marca.....	53
4.7	Intención de recompra.....	54
5.	Metodología.....	55
5.1	Muestra	55

5.2 Cuestionario	56
5.2.1 Términos y condiciones de participación.....	56
5.2.2 Hábitos de compra y frecuencia de uso de redes sociales.....	56
5.2.3 Constructos.....	57
5.2.4 Datos demográficos.....	59
5.3 Análisis de datos.....	60
5.3.1 Análisis de fiabilidad interna mediante Alpha de Cronbach.....	60
5.3.1 Modelamiento de ecuaciones estructurales (SEM).....	61
6. Resultados y análisis.....	62
6.1 Perfil demográfico de los encuestados	62
6.1.1 Género	63
6.1.2 Edad.....	64
6.1.3 Ingresos	66
6.1.4 Educación.....	68
6.2 Comportamiento del consumidor.....	70
6.2.1 ¿Con qué frecuencia compras productos de moda?	71
6.2.2 ¿Dónde realizas la mayoría de tus compras de moda?.....	72
6.2.3 ¿Cuál es el gasto promedio en una compra de moda?	74
6.2.4 ¿Con qué frecuencia utilizas redes sociales? (por ejemplo, Instagram, Facebook, TikTok, Pinterest, X (antes Twitter), YouTube, entre otras).....	75
6.2.5 ¿Qué tan seguido interactúas (haciendo clic, guardando, enviando, compartiendo, etc) con anuncios dirigidos en redes sociales relacionados con moda?	76
6.2.6 ¿Qué tan relevante consideras la personalización de los anuncios de moda que ves en redes sociales?... 77	
6.2.7 Marcas de moda has interactuado utilizando herramientas de IA.....	78
6.3 Fiabilidad de constructos	79
6.4 Modelación del impacto de la IA en la personalización de recomendaciones de compra.....	81
6.5 Resultados del análisis confirmatorio	83
6.5.1 Evaluación del Modelo en AMOS	83
6.5.2 Índices de Bondad de Ajuste.....	84
6.5.3 Estimaciones de Regresión y Relaciones entre Variables.....	85
6.5.4 Coeficiente de Determinación (R2)	86
6.5.5 Evaluación de Hipótesis.....	87
6.5.6 Análisis de efectos estructurales directos e indirectos	88
6.5.7 Evaluación de ítems problemáticos.....	91
7. Modificación del modelo.....	92
7.1 Eliminación de constructo accesibilidad(ACC)	92
7.1.2 Índices de modificación	93

7.1.3 Implementación modificaciones	95
7.2 Eliminación constructo Interacción (INT)	98
7.1.2 Índices de modificación	99
7.2.3 Implementación modificaciones	101
7.3 Análisis estimaciones de regresión y relaciones entre variables.....	103
7.4 Análisis de efectos estructurales modelo modificado.....	105
8. Conclusiones y recomendaciones	110
8.1 Conclusiones	110
8.2 Recomendaciones	114
9. Limitaciones	117
10. Referencias	119

1. Problema de investigación

La inteligencia artificial ha transformado de manera significativa la industria del marketing digital al permitir la personalización de anuncios en tiempo real mediante el análisis de grandes volúmenes de datos.

Esta tecnología ayuda a optimizar las campañas publicitarias ayudando a las empresas a dirigir anuncios precisos y relevantes para su audiencia, otorgándoles una ventaja competitiva en sus mercados. Según un estudio de (McKinsey & Company, 2023), las empresas que adoptan IA en sus estrategias de marketing experimentan mejoras significativas en la efectividad de sus campañas, donde tienen un aumento del 20% de los ingresos los que se atribuyen al uso de la IA, principalmente en industrias como el retail y las telecomunicaciones. En el caso de la industria de la moda, la IA permite personalizar recomendaciones de productos en función de las preferencias individuales de los consumidores, aumentando su conexión emocional con las marcas y buscando la fidelización a largo plazo. Estas tecnologías permiten ajustar los anuncios a las preferencias de los consumidores con mayor precisión lo que incrementa la satisfacción, eficiencia y relevancia de las campañas (McKinsey & Company, 2023).

Sin embargo, este crecimiento a pasos agigantados de la IA no se encuentra exento de desafíos, donde uno de los principales es la preocupación de los consumidores por la privacidad de sus datos , la ética en su utilización y la transparencia con que las empresas manejan la información. A medida que las marcas de moda implementan IA para personalizar recomendaciones y optimizar sus campañas, surge una pregunta clave **¿Cómo perciben los consumidores el uso de tecnologías como la inteligencia artificial en su experiencia de compra?.** Un estudio de (Forrester, 2023) indica que, si bien los consumidores valoran los beneficios de la personalización, también muestran reservas en cuanto al uso de sus datos personales y la falta de transparencia en los algoritmos empleados. En la industria de la moda, esto

podría tener un impacto significativo, dada la importancia de la confianza y las conexiones emocionales que se buscan construir entre los consumidores y las marcas. Algunas marcas utilizan IA para mejorar la precisión de los anuncios, pero deben mitigar los riesgos percibidos relacionados con la manipulación de datos y la posible invasión de la privacidad, aspectos que los consumidores observan con creciente preocupación (Forrester, 2023).

En el contexto Chileno, la publicidad digital ha crecido de manera significativa, alcanzando aproximadamente un 51% de los presupuestos publicitarios totales en el año 2023, reflejando un aumento notable en comparación a las cifras del año 2015 donde solo alcanzaba un 15% de dicho presupuesto. Este crecimiento exponencial a través de los años ha sido impulsado en gran parte por el uso de tecnologías como la inteligencia artificial (IA), permitiendo una mayor precisión tanto en la segmentación de audiencias como en la personalización de anuncios. En el caso de las marcas de moda, estas tecnologías han sido útiles principalmente para captar la atención del segmento más joven, a través de plataformas como Instagram y TikTok, los cuales han demostrado ser canales efectivos para conectar con este tipo de audiencias. Los sectores que lideran este avance son el sector del retail, con una inversión de 257 millones de dólares y el sector financiero con 113 millones de dólares. Dentro de la publicidad digital, son las redes sociales y el video digital quienes han experimentado mayores incrementos en su utilización con un 23% y 3% de crecimiento respectivamente, en comparación a otros formatos de publicidad convencionales como lo son la televisión o revistas, que han visto una disminución en su participación (Adlantina, 2023; SCOPEN, 2023). A partir de este escenario, surgen las siguientes interrogantes:

¿Cómo perciben los consumidores el uso de anuncios personalizados dirigidos por inteligencia artificial en las marcas de moda en Chile?

¿Qué nivel de consciencia tienen los consumidores de moda sobre el uso de algoritmos de IA

para la personalización de recomendaciones de compra a través de anuncios dirigidos?

¿De qué manera influye la personalización de recomendaciones mediante IA en la confianza, satisfacción y lealtad de los consumidores hacia las marcas de moda?

¿En qué medida la precisión y relevancia de las recomendaciones personalizadas generadas por IA impactan las decisiones de compra de los consumidores en el sector moda?

2. Objetivos

2.1 Objetivo General

Realizar un análisis del impacto del uso de la Inteligencia Artificial en la personalización de recomendaciones de compra a través de anuncios dirigidos en marcas de moda, su influencia en la percepción y decisiones de compra de los consumidores en Chile.

2.2 Objetivos Específicos

- Identificar cómo perciben los consumidores de moda el uso de anuncios personalizados dirigidos por Inteligencia Artificial en Chile.
- Evaluar el nivel de consciencia de los consumidores de moda sobre el uso de algoritmos de Inteligencia Artificial en la personalización de recomendaciones de compra y analizar como esto influye en sus decisiones de compra.
- Determinar cómo la personalización de recomendaciones mediante IA influye en la confianza, satisfacción y lealtad de los consumidores hacia las marcas de moda que emplean esta tecnología en sus estrategias publicitarias.
- Analizar las diferencias en la percepción y en las decisiones de compra de los consumidores según variables demográficas como la edad, género, ingresos y nivel educativo en respuesta a las recomendaciones personalizadas.
- Medir el impacto de la precisión y relevancia de las recomendaciones personalizadas generadas por IA en la toma de decisiones de compra de los consumidores en el sector de la moda.

3. Marco Teórico

3.1 Publicidad digital y personalización de la publicidad

¿Qué es publicidad?

La publicidad es una forma de comunicación destinada a promover productos, servicios o ideas, y no se limita exclusivamente a los fines comerciales. Se considera que los textos publicitarios implican potencialmente nociones complejas de audiencia, donde los lectores tienen que esforzarse mucho para decodificar los mensajes y comprender diferentes relaciones de destinatarios (Goddard, 1998). Esto resalta la importancia de utilizar estrategias que capturen la atención del público y los inviten a participar en el proceso de interpretación del mensaje.

En la industria de la moda, la publicidad juega un rol crucial, ya que no solo vincula los productos con necesidades funcionales, sino con aspiraciones de los consumidores, valores y estilos de vida. En este sector, se han aprovechado ampliamente las estrategias narrativas y visuales, desde desfiles de alta costura hasta experiencias inmersivas en redes sociales como TikTok o Instagram, que apelan a audiencias que conecten emocionalmente con las marcas (Zúñiga Vásquez, Mora Poveda, & Llerena Llerena, 2023).

Publicidad digital

La publicidad digital hace referencia a la promoción de productos, servicios o marcas a través de medios digitales. Hoy en día se constituye como una de las principales formas de comunicación directa entre las empresas y el público, donde además se incluye la personalización del contenido. Esta comunicación se debe realizar en el momento oportuno para maximizar las interacciones con los consumidores. Uno de los enfoques más destacados dentro de la publicidad digital es el marketing en redes sociales, ya que permiten conectar a las empresas con grandes

audiencias, optimizando las relaciones con los clientes mediante los distintos medios digitales (Rocha, Reis, Peter, & Bogdanović, 2019).

En el caso de las marcas de moda, las redes sociales representan el canal principal para la publicidad digital, ya que el público objetivo en esta industria tiende a consumir un mayor contenido visual. Plataformas como TikTok e Instagram y su gran crecimiento durante estos últimos años, han facilitado que las marcas diseñen campañas visuales y de video que conecten emocionalmente con los consumidores. Según IAB Chile (2024), el 65% de las interacciones de usuarios entre 18 y 34 años están vinculadas a campañas de moda en redes sociales, lo que evidencia el impacto de estas estrategias en la industria (IAB Chile, 2024).

Personalización de la publicidad

La personalización en la publicidad hace referencia al proceso mediante el cual los anuncios publicitarios son adaptados a las preferencias y comportamientos de los consumidores de manera individual, permitiendo crear una comunicación más efectiva y relevante con mensajes específicos para cada usuario. Según Rocha (2019), “el marketing digital permite una relación igual y personalizada con el cliente, lo que es fundamental para la personalización de la publicidad” (p. 140).

Además, con el uso de las redes sociales como uno de los canales de comunicación más usado, ha transformado las formas en que las empresas interactúan con los consumidores, donde el uso de Inteligencia Artificial y Big Data es cada vez más común, ya que permiten a las plataformas publicitarias recopilar una gran cantidad de datos para crear anuncios personalizados y ajustados a las preferencias e intereses de los usuarios. Esta estrategia no solo mejora la experiencia del cliente, sino que entrega un mayor nivel de lealtad , debido a que “la

personalización de la publicidad influye en las decisiones de compra de los consumidores” (Rocha, Reis, Peter, & Bogdanović, 2019, p. 323).

Es por ello, que la personalización en la publicidad no solo se limita a la adaptación de mensajes personalizados al consumidor, sino que también abarca la optimización de la experiencia del consumidor permitiendo a las marcas crear relaciones sólidas con sus clientes al ofrecer contenido que resuene con sus intereses y necesidades. En el caso de las marcas de moda, esta conexión es aún más crítica, ya que los consumidores suelen buscar experiencias alineadas con su identidad y estilo de vida. Este enfoque logra captar su atención y fomenta un sentido de conexión y lealtad, lo cual se traduce en un mayor compromiso del cliente, ya que los consumidores son más propensos a interactuar con anuncios que consideran relevantes y útiles para sus intereses personales.

Además, la personalización puede extenderse más allá de la publicidad tradicional, integrándose en la experiencia general del cliente a través de acciones como recomendaciones de productos, correos electrónicos dirigidos o contenido personalizado en redes sociales tales como Instagram, TikTok, Youtube, plataformas claves en el sector de la moda. Por ejemplo, el uso de inteligencia artificial permite generar propuestas personalizadas según la temporada, los estilos preferidos o tendencias. En este contexto, la inteligencia artificial y el análisis de datos juegan un papel fundamental, ya que permiten a las empresas no solo comprender mejor a sus clientes, sino adaptarse rápida y eficientemente a sus cambiantes preferencias y comportamientos (Salgado Reyes, 2023).

En el contexto de la moda, la personalización permite a las marcas conectar de manera más

profunda con sus consumidores al ofrecerles productos que no solo coincidan con sus preferencias, sino también con su identidad personal. Los algoritmos generados por IA desempeñan un papel fundamental en este proceso, ajustando recomendaciones basadas en comportamientos previos y datos demográficos. Estas estrategias mejoran tanto la percepción del valor como la lealtad hacia las marcas (Zúñiga Vásquez, Mora Poveda, & Molina Mora, 2023).

Contexto global de la publicidad digital

La publicidad digital ha transformado a través del tiempo la forma en la que las empresas llegan a sus consumidores, desplazando progresivamente a los medios tradicionales. Este cambio ha sido impulsado principalmente por el exponencial crecimiento del acceso a internet, el uso de dispositivos móviles y el desarrollo de nuevas tecnologías como la Inteligencia Artificial y Big Data. Según el Interactive Advertising Bureau(IAB), la inversión global de publicidad digital alcanzó cifras máximas históricas, reportando ingresos de 225 mil millones de dólares entre 2022 y 2023, un aumento del 7,3% respecto al año anterior. Este crecimiento fue liderado por la publicidad en video, que incrementó un 10,6% en el comercio minorista, consolidándose como un canal clave para las marcas en plataformas como YouTube y TikTok (IAB, 2024).

En la industria de la moda, las plataformas de video y redes sociales han jugado un papel clave, ya que permiten a las marcas mostrar sus productos de manera visual e impactante, adaptándose a lo que buscan las audiencias jóvenes y tecnológicamente conectadas (IAB Europe, 2024).

El marketing en redes sociales ha jugado un papel clave siendo uno de los principales motores de crecimiento, luego de que existiera un período de desaceleración el año 2022. El año 2023 los ingresos por publicidad en redes sociales tuvieron un aumento del 8,7% dejando en

evidencia la importancia del marketing a través de los creadores de contenidos y nuevas formas de interacción presentes en dichas plataformas (IAB, 2024). Además, la publicidad programática, que hace referencia a la compra automatizada de espacios publicitarios a través de plataformas tecnológicas y que optimiza la entrega de anuncios a audiencias específicas basados en datos, continua dominando el ecosistema publicitario ya que representa el 51,9% de la publicidad gráfica, lo que evidencia la importancia de la automatización, el uso de datos y de algoritmos para segmentar las audiencias (IAB Europe, 2024).

El uso de la Inteligencia Artificial (IA) en la publicidad digital ha transformado la forma en la cual las empresas interactúan con sus consumidores, ya que permite desde la personalización masiva de anuncios, como la predicción y el estudio de comportamientos y la automatización a gran escala de los procesos publicitarios, lo cual ha mejorado tanto la eficiencia como la efectividad de las campañas. Por otro lado, ha logrado que los anuncios sean relevantes para los consumidores a través de la dirección de estos utilizando datos en tiempo real que permitan ajustar mensajes adecuados a las preferencias individuales de los usuarios, lo que ha dado paso a nuevas oportunidades para la publicidad predictiva, que permite a los anunciantes anticipar las necesidades y comportamientos de los consumidores antes de que estos realicen una compra, lo cual ha permitido mejorar las tasas de conversión y lealtad hacia las marcas. En el caso de las marcas de moda, la IA ha sido clave para prever tendencias, diseñar colecciones y personalizar campañas publicitarias según los gustos de sus clientes, lo que ha elevado la percepción de exclusividad y sofisticación en estas marcas.

Tecnologías como el Machine Learning y el Deep Learning han sido fundamentales para este avance. Machine Learning permite a las máquinas aprender a través de los grandes volúmenes de datos procesados mejorando continuamente sin intervención humana, mientras que Deep

Learning utiliza redes neuronales profundas para procesar y analizar datos complejos ofreciendo predicciones más acertadas. Estas tecnologías permiten analizar grandes volúmenes de datos en tiempo real, entregando una segmentación mucho más precisa y con mensajes altamente personalizados para el consumidor. Es por ello que la IA es un componente clave del marketing digital y según un estudio realizado por Muhammadian (Muhammadian, 2020) la IA está revolucionando la publicidad ya que permite que las empresas logren mejores resultados en su publicidad a pesar de utilizar menos recursos para esta, debido a su capacidad de analizar y procesar datos en tiempo real.

La IA en la publicidad enfrenta desafíos importantes, una de las principales preocupaciones es acerca de la privacidad de los datos y la ética en el manejo de la información personal. Al permitir almacenar y analizar cantidades masivas de datos sobre los comportamientos y preferencias de los consumidores, generando inquietud sobre la manipulación del comportamiento y la invasión de la privacidad. Por ello, consumidores y organismos reguladores buscan que las empresas sean más transparentes y responsables con el uso de estas herramientas.

En Europa, se han implementado normativas como el Reglamento general de Protección de Datos(GDPR), que ha obligado a las empresas a desarrollar nuevas estrategias de personalización que buscan generar un balance entre la efectividad publicitaria y la protección de la privacidad de los consumidores, promoviendo así un uso más responsable y transparente de la IA sin comprometer la eficiencia de las campañas.

Publicidad Digital en Chile

En Chile, la publicidad digital ha crecido de forma sostenida alcanzando en el año 2023 un 52,3% del total de la inversión publicitaria, lo que significa que más de la mitad del presupuesto que las empresas destinan a publicidad fue dirigido a medios digitales. Este crecimiento ha sido impulsado por sectores como el retail y las telecomunicaciones, que lideran el uso de estrategias digitales. Las plataformas de redes sociales, anuncios en línea y banners digitales se han consolidado como las herramientas más utilizadas por las empresas para conectar con sus consumidores y optimizar las campañas en el mercado local. (Asociación de Agencias de Medios, 2023).

La industria del retail en Chile es una de las que mayor crecimiento en publicidad digital ha experimentado, logrando consolidar sus estrategias de marketing digital a través de diversas herramientas que han permitido su evolución como los son la publicidad programática y la automatización de los espacios publicitarios, dichas herramientas son respaldadas y apoyadas en gran parte por la Inteligencia Artificial la cual ha permitido analizar diversas y grandes cantidades de datos para personalizar anuncios y optimizar el rendimiento, donde se utilizan algoritmos de machine learning para tomar decisiones automáticas sobre que anuncios mostrar, a que tipo de usuarios y en que horario, mejorando la precisión en las diversas campañas. En el caso de las marcas de moda, el uso de la publicidad programática también ha sido clave para alcanzar audiencias específicas interesadas en tendencias y colecciones particulares. Estas estrategias permiten a las marcas destacar en un mercado competitivo, maximizando el impacto de sus campañas publicitarias.

En el año 2023, nuestro país se ubicó como el tercer mercado más importante en términos de inversión publicitaria digital en Latino América, siendo superado solo por Brasil y México. Este posicionamiento refleja la rápida adopción de herramientas digitales y el avance del

Marketing digital, donde como se mencionó anteriormente destacan sectores como el retail y las telecomunicaciones. Según el último informe realizado por Agency Scope Chile, este crecimiento ha sido sostenido desde el año 2014, donde las principales plataformas para capitalizar esta inversión han sido Facebook, Instagram y Youtube (SCOPEN, 2023).

En la industria de la moda en Chile, plataformas como Instagram y TikTok han sido muy importantes debido a su enfoque en contenido visual, ideal para promocionar productos de moda. Es por ello que marcas nacionales e internacionales han aprovechado estas plataformas para lanzar colecciones y captar a consumidores más jóvenes, interesados en tendencias globales y locales.

Otro factor importante en el panorama chileno ha sido el crecimiento de la publicidad en video donde plataformas como TikTok y Youtube han abarcado la mayor parte de la inversión publicitaria debido a su capacidad de atraer e influenciar a las audiencias más jóvenes, se estima que la inversión en este tipo de publicidad aumentó un 18% el 2023, lo cual contribuye a la idea de que la creación de contenido visual e interactivo es una de las estrategias fundamentales del marketing (IAB Chile, 2024).

En el marco legal Chile ha avanzado en la protección de datos personales a través de un Proyecto de Ley que tiene como objetivo fortalecer las normativas relacionadas con la privacidad, la ética y el manejo de datos en entornos digitales, este proyecto busca garantizar que los usuarios entreguen consentimiento explícito para que las empresas la utilicen para fines publicitarios. Esta tendencia en la Sudamérica se refleja en países como Brasil, que implementó la Lei Geral de Proteção de Dados (LGPD), normativa que ha servido de inspiración para el desarrollo de regulaciones similares en Chile. Estas iniciativas responden a la creciente preocupación por el uso de datos en la publicidad digital y el riesgo de invasión de la privacidad, obligando a las empresas

a ser más transparentes y responsables en su manejo de información (Gobierno de Chile, 2023).

3.2 Beneficios del uso de Inteligencia artificial en la publicidad

La segmentación, la personalización, la creación de contenido y la optimización de anuncios

La Inteligencia Artificial (IA) ha revolucionado el marketing digital, permitiendo a las empresas y marcas no solo aumentar su alcance, sino que optimizar la segmentación de las diversas campañas. Uno de los beneficios principales de la IA en la publicidad es la capacidad de esta para analizar grandes volúmenes de datos en tiempo real, lo cual permite a las empresas a identificar los patrones de comportamiento de sus consumidores para así poder ajustar sus estrategias publicitarias tanto en contenido, horario, plataformas, entre otras. Según estudios recientes, la IA utiliza algoritmos avanzados que procesan información de diferentes fuentes, como el historial de navegación, las interacciones en redes sociales y las compras anteriores, para determinar con mayor precisión qué mensajes son más relevantes para cada segmento de audiencia (Zúñiga Vásquez, Mora Poveda, & Molina Mora, 2023).

La IA permite segmentaciones al dividir las audiencias en subgrupos basados en criterios como edad, género, intereses personales y comportamiento en redes sociales. Esta microsegmentación optimiza el alcance de los anuncios debido a que permite a las empresas a llegar a los usuarios o consumidores correctos en el momento indicado para influir en sus decisiones de compra, maximizando la eficiencia de las campañas publicitarias. Como resultado, la publicidad digital se vuelve más personalizada y efectiva, mejorando tanto la experiencia del usuario como el retorno de la inversión de las empresas. En el sector de la moda, esta microsegmentación se ha vuelto esencial, ya que permite a las marcas adaptar sus mensajes a audiencias con intereses específicos, como estilo, colores o tendencias. Esto ha optimizado tanto las tasas de conversión como la fidelización de los consumidores.

Es por ello por lo que la segmentación, la personalización, la creación de contenido y la optimización de anuncios pueden verse como los cuatro pilares principales de la IA basada en publicidad computacional, ya que funcionan de manera conjunta y colaborativa dentro de los ecosistemas publicitarios. Un concepto que incorporar es el modelado de usuarios como enfoque común en la publicidad computacional, donde se construyen modelos que predicen la respuesta de un usuario a anuncios específicos, basándose en su comportamiento pasado tanto como historial de navegación, historial de compras, uso en redes sociales e información demográfica (Gao, Wang, Xie, & Hu, 2023). En relación con la personalización, existen sistemas especializados que filtran la información que ayudan a predecir el gusto de un usuario, ya que pueden mostrar de manera cuantificable el estado emocional de los consumidores hacia un anuncio en particular (Kietzmann, Paschen, & Treen, 2018). Dentro da industria de la moda, estas tecnologías han permitido predecir con mayor precisión qué colecciones o estilos serán más populares, permitiendo así el ajuste personalizado de las campañas publicitarias.

La creación de contenido publicitario ha sido transformada debido al uso de diversas tecnologías como lo es el procesamiento de lenguaje natural (PNL) que permite que las maquinas adopten, procesen y generen un lenguaje humano, lo que ayuda en creación de guiones, descripciones de productos, textos o eslóganes publicitarios. Por otro lado, la utilización de Inteligencia Artificial generativa es utilizada para crear contenido multimedia como imágenes o videos a partir de datos preexistentes. Un ejemplo de ello es en el ámbito de la moda, donde estas herramientas han facilitado la creación de catálogos interactivos y visuales que generan experiencias inmersivas para los consumidores.

La optimización de anuncios es considerada como el tema central en la publicidad

computacional, esto hace referencia a como mostrar anuncios efectivos a aquellos usuarios que están más interesados a partir de un presupuesto limitado (Nikolajeva & Teilans, 2021), así asegurándose que cada dólar invertido en anuncios sea utilizado de manera eficiente para obtener el mejor retorno de la inversión posible. La inteligencia artificial ha permitido mejorar tanto la eficiencia como la efectividad de la publicidad utilizando técnicas avanzadas como el Problema del Bandido de Múltiples Brazos, se busca optimizar las decisiones publicitarias mediante la elección entre diversas estrategias o anuncios, enfrentando siempre un cierto nivel de incertidumbre sobre cuál de ellas generará mejores resultados.

El Deep learning o aprendizaje profundo permite que los sistemas de Inteligencia Artificial procesen grandes volúmenes de datos, permitiendo una mejor segmentación de audiencias y aumentando la efectividad y precisión en los anuncios. Estas tecnologías identifican patrones complejos en el comportamiento del consumidor, prediciendo que anuncios tendrán mayor impacto en cada grupo de consumidores. Otro aspecto clave en la optimización continua de las campañas publicitarias es el Reinforcement learning o aprendizaje por refuerzo, ya que mediante un proceso de prueba y error los algoritmos aprenden a tomar mejores decisiones, ajustando sus estrategias en tiempo real para maximizar sus resultados.

Automatización de procesos

En la actualidad, la automatización de procesos publicitarios es una tendencia crucial que ha tomado cada vez más relevancia en la industria del marketing digital. Debido a la creciente complejidad en las campañas publicitarias y la necesidad de optimizar los recursos, el uso de herramientas como la inteligencia artificial y el aprendizaje automático, que han facilitado la automatización tanto en la creación, distribución y optimización de la publicidad. Según Hrabovskyi (2021) la automatización ha permitido que las empresas amplíen considerablemente

sus estrategias de marketing, optimizando el rendimiento mediante la programación precisa de aspectos como la hora, la ubicación y el formato de los anuncios, siempre en función del comportamiento de la audiencia y dentro de los límites presupuestarios establecidos. En la industria de la moda, la automatización ha sido clave para gestionar lanzamientos de colecciones, campañas promocionales y ofertas específicas, adaptándose en tiempo real al comportamiento de los consumidores.

Además de la automatización básica, también se aplican metodologías más avanzadas como lo es el análisis de jerarquía, ya que facilita la toma de decisiones al descomponer problemas complejos en niveles jerárquicos. Además, esta técnica permite priorizar criterios claves como lo son el comportamiento del consumidor, las condiciones del mercado y los objetivos de la campaña (Hrabovskyi, 2021).

Otro recurso importante que se utiliza es la puja en tiempo real (RTB) que automatiza la compra de espacios publicitarios a través de subastas instantáneas que ocurren cada vez que un usuario accede a los distintos contenidos que hay en línea. Los algoritmos de IA ajustan las distintas ofertas en base al perfil del usuario, maximizando la relevancia del anuncio y el retorno de la inversión evitando las intervenciones manuales continuas (Szymczyk & El Emary, 2021).

Sistema CRM

Un sistema CRM o Customer Relationship Management se traduce como la Gestión sobre la Relación con los Consumidores, refiriéndose a una estrategia de negocios basada en el cliente. Según De Goyeneche (2002) “CRM es un modelo de negocios destinado a gestionar relaciones con las cuentas más valiosas para la empresa, mejorando la efectividad sobre los clientes”. Estos sistemas permiten gestionar, centralizar y automatizar, facilitando interacciones personalizadas

que promueven su retención y satisfacción. La consolidación de información clave de los clientes en bases de datos accesibles para los diversos departamentos de una organización mejoran la eficiencia. Según Salesforce y CRM.org, más del 91% de las empresas con más de 10 empleados usan CRM para gestionar ventas, marketing y soporte al cliente (CRM.org, 2024;Salesforce,2024). En la industria de la moda, el uso de CRM ha permitido a las marcas gestionar programas de fidelización, realizar seguimientos personalizados a sus clientes y ofrecer recomendaciones basadas en compras anteriores, generando una experiencia más personalizada y satisfactoria.

Actualmente la inteligencia artificial(IA) y la automatización son fundamentales de plataformas CRM modernas, ya que permiten priorizar potenciales clientes y mejorar las campañas de marketing, donde herramientas como Salesforce, HubSpot y Microsoft Dynamics destacan por su facilidad de uso, al automatizar tareas repetitivas, reduciendo esfuerzos manuales y aumentando la eficiencia operativa (CRM.org, 2024). En el mercado local, el 93% de las PYMEs ha invertido en tecnología digital para sus empresas, donde se incluye el CRM, siendo un factor crucial en su proceso de transformación, esto ha sido incentivado y respaldado por la iniciativa Digitaliza tu Pyme (Microsoft News Center, 2024).

En la publicidad digital, los sistemas CRM buscan segmentar audiencias en tiempo real y personalizar campañas. Se ha identificado que las empresas que comienzan a utilizar CRM tienen un aumento del 17% de conversión de clientes potenciales a clientes y un 21% de mejora en su productividad, donde, además, estas mejoras se ven reflejadas en la reducción de los ciclos de ventas entre un 8% a 14% y una maximización del retorno de inversión hasta en un 245% inclusive (CRM.org, 2024).

3.3 Comportamiento del consumidor en la Publicidad Digital

El comportamiento del consumidor hace referencia al proceso mediante el cual los individuos seleccionan, compran, usan y desechan tanto productos como servicios para satisfacer sus necesidades. No solo basado en sus decisiones de compra sino también en emociones, actitudes y percepciones que pueden influir en dichas decisiones. Factores como el entorno social, cultural o tecnológico de igual manera tienen un impacto en el comportamiento, generando un panorama complejo para las empresas quienes deben analizar estos factores para diseñar estrategias efectivas (Solomon, 2008; Schiffman & Kanuk, 2010).

En el Marketing Digital, el comportamiento del consumidor juega un rol principal, ya que existe la posibilidad de recopilar y analizar datos a través de herramientas digitales para realizar segmentaciones del mercado, realizando así campañas más personalizadas que responden de mejor manera a las necesidades y deseos de los consumidores. La personalización mediante algoritmos y anuncios dirigidos aumenta la relevancia de los mensajes, lo que a su vez mejora la satisfacción del cliente y la efectividad de las campañas (Peter & Olson, 2006; Solomon, 2008). Es por ello por lo que la segmentación basada en datos permite que las empresas puedan adaptar sus estrategias y campañas a las preferencias y comportamiento de los diferentes grupos de consumidores.

La construcción de experiencias de valor son un elemento crucial en el marketing digital, ya que hoy en día las marcas no solo deben ofrecer productos o servicios de calidad, sino también involucrarse con sus consumidores entregando experiencias personalizadas, lo cual incrementa la lealtad del cliente. Las experiencias personalizadas no solo aumentan las probabilidades de conversión, sino que también diferencian a las marcas en mercados altamente competitivos (Schiffman & Kanuk, 2010). En este proceso la Inteligencia Artificial juega un rol fundamental ya que permite analizar grandes volúmenes de datos en tiempo real para ofrecer recomendaciones

personalizadas.

En el sector del retail, esta personalización se observa especialmente en estrategias que integran tanto experiencias digitales como físicas, permitiendo a los consumidores interactuar con las marcas en múltiples puntos de contacto. En el caso de la moda, estas estrategias destacan al crear experiencias inmersivas, como catálogos virtuales o recomendaciones basadas en tendencias.

De la misma forma, la tecnología digital ha redefinido la toma de decisiones de los consumidores ya que entrega acceso inmediato a la información, productos y servicios. Los consumidores tienen mayores expectativas de respuesta rápida y personalización en cada punto de contacto con las marcas (Solomon, 2008). Por otro lado, los consumidores confían cada vez más en las opiniones y recomendaciones de otros usuarios en línea, lo que hace que la reputación digital de las marcas sea un factor determinante en su éxito (Schiffman & Kanuk, 2010). Es por ello, que las estrategias de marketing que integran de forma efectiva la participación del consumidor en las redes sociales logran aumentar la fidelización y mejorar la percepción de las marcas.

Proceso de toma de decisiones del consumidor ante la publicidad digital personalizada

El comportamiento del consumidor en la publicidad digital personalizada abarca múltiples canales y factores que influyen en la toma de decisiones. Dentro de estos canales y factores podemos identificar la publicidad programática y la puja en tiempo real (RTB) las cuales permiten que los anuncios se vayan ajustando al perfil del usuario de manera instantánea, optimizando así la relevancia de estos y aumentando las tasas de conversión (Salesforce, 2024). A su vez, los anuncios en motores de búsqueda y en formato display aprovechan intenciones de compras previas para aumentar la efectividad de las campañas (Urueña, Ferrari, Blanco, & Valdecasa, 2011). Otro factor importante que considerar, son los principios psicológicos tales como la reciprocidad y la

escasez los cuales juegan un papel fundamental en la forma en la que los consumidores responden a estos anuncios personalizados, generando emociones que los acerquen a la compra (Schiffman & Kanuk, 2005).

En plataformas de video como TikTok y Youtube, las marcas de moda han invertido de mayor forma en los anuncios interactivos para fomentar la retención del mensaje. Al mostrar colecciones o realizar lanzamientos mediante formatos de videos dinámicos, logrando captar la atención de los consumidores y aumentar las intenciones de compras. Sin embargo, la efectividad de estos anuncios dependerá de la confianza que posea el consumidor hacia las empresas, por lo que se destaca la importancia de equilibrar la personalización con la privacidad y el manejo ético y transparente de los datos almacenados (Salesforce, 2024).

Preferencias del consumidor según formato y canal publicitario

El comportamiento del consumidor no varía solo por la relevancia del contenido expuesto, sino que también por la experiencia multicanal que las empresas ofrecen. Como cada canal cumple un rol diferente los consumidores valoran la comodidad que existe al alternar entre canales físicos y digitales para su proceso de compra (Andersen, Weisstein, & Song, 2019). Un ejemplo común de este caso es que los usuarios busquen en línea información técnica y detallada y luego visiten la tienda física para completar su compra, esto refleja la importancia de integrar de buena manera ambos entornos.

Las estrategias multicanal combinan tanto la publicidad digital con puntos de venta físicos, generando una mayor satisfacción de los clientes y fortaleciendo la relación, ya que permite a los consumidores elegir el canal más conveniente, aumentando la probabilidad de conversión y fomentando la lealtad hacia la marca. Por otro lado, se observa que los consumidores responder

mejor a experiencias coherentes y personalizadas entre diferentes plataformas, lo que indica que las empresas deben alinear de mejor manera su mensaje y oferta en los diversos canales tanto físicos como digitales (Andersen, Weisstein, & Song, 2019).

En el ámbito de la moda, esta estrategia multicanal resulta esencial, ya que los consumidores buscan experiencias integradas que les permitan explorar productos en línea, probarlos en tiendas físicas y completar sus compras en el canal que consideren más cómodo. Otro factor importante en la decisión de compra es el valor del canal, ya que los consumidores preferirán canales que ofrezcan comodidad, flexibilidad y transparencia, es decir, aquellos que combinen la facilidad de navegación y la eficiencia en el servicio. Es por ello que la capacidad de una empresa para integrar publicidad relevante en un ecosistema multicanal es un proceso fundamental para mejorar la experiencia de los usuarios y asegurar su fidelidad (Sicilia, Palazón, & López, 2016).

Impacto de la personalización en la satisfacción y lealtad del consumidor

La personalización se ha convertido en la última década se ha convertido en una estrategia fundamental para las empresas que buscan mejorar la satisfacción y la lealtad del cliente. Según Kasiri et al (2017) la personalización permite que las organizaciones adapten tanto sus productos y servicios a las necesidades individuales y específicas del consumidor, aumentando su percepción de valor y satisfacción. La personalización se diferencia de los enfoques estandarizados en que ofrece una experiencia diferenciada y responde a las necesidades y expectativas de cada cliente, fomentando el compromiso y la lealtad de este.

Dentro de este contexto, los sistemas Customer Relationship Management (CRM) facilitan este proceso, avanzando y transitando hacia la hiperpersonalización, que se trata de un modelo más avanzado de la personalización, utilizando datos en tiempo real y algoritmos de inteligencia

artificial para ofrecer recomendaciones precisas basadas en el comportamiento pasado y las preferencias del usuario (Rane, Choudhary, & Rane, 2023) .Este proceso de hiperpersonalización permite una gestión más eficiente entre la organización y el cliente, ayudando a generar interacciones que incrementan la satisfacción y la probabilidad de una nueva compra, creando una relación más sólida y duradera con los clientes. En sectores como el retail de lujo y la moda, esta hiperpersonalización es clave para ofrecer experiencias exclusivas que refuercen la percepción de valor y diferenciación de las marcas.

Influencia de los factores demográficos y psicológicos en la percepción de la publicidad personalizada

La percepción de la publicidad personalizada está condicionada por factores tanto demográficos como psicológicos los cuales moldean las respuestas del consumidor a los anuncios, involucrando tanto la edad, el género, el nivel de educación y socioeconómico, los cuales afectan las expectativas y la disposición del consumidor. Según Galdos Frisancho (2024), los consumidores más jóvenes tanto Millennials como Centennials muestran un mayor nivel de interacción con anuncios en plataformas digitales y redes sociales, mientras que personas más adultas y adultos mayores siguen prefiriendo canales más tradicionales como lo es el correo electrónico. Datos recientes dan a conocer que más del 61% de la audiencia de Instagram tiene entre 18 y 34 años, mientras que solo el 7% tiene más de 55 años, destacando la importancia de la segmentación de campañas según edad (DataReportal, 2023).

Otro factor importante que considerar es el género en la segmentación de campañas, un ejemplo claro de esto es analizar las plataformas de mayor uso de los consumidores. Es posible identificar que las mujeres son quienes realizan en mayor proporción compras mediante plataformas como Instagram, principalmente en artículos de moda y cuidado personal, destacando

una vez más la importancia de segmentar las campañas a las preferencias de cada género (SEMrush, 2024).

Asimismo, el análisis psicológico de los consumidores en el sector de la moda revela que las emociones juegan un papel fundamental, donde campañas que apelan a los sentimientos de pertenencia o exclusividad logran un mayor impacto en la intención de compra. Según el nivel socioeconómico los consumidores responden de manera diferente a los anuncios según las características de su mayor interés, los consumidores con mayores ingresos tienden a responder de mejor manera a anuncios que destacan la calidad y la exclusividad, por otro lado los de menores ingresos prefieren campañas que se centren en promociones y descuentos (Kasiri, Guan Cheng, Sambasivan, & Sidin, Integration of standardization and customization: Impact on service quality, customer satisfaction, and loyalty, 2017). Por otro lado, los anuncios que apelan a las emociones y sentidos generan una mayor respuesta por parte del consumidor, es por ello que plataformas como TikTok que ofrecen experiencias interactivas y entretenidas tienden a activar este tipo de impulso, donde los usuarios de TikTok tienen 1.5 veces más de probabilidades de realizar una compra de manera inmediata luego de descubrir un producto en la plataforma (Khoros, 2022).

Otra herramienta utilizada en las experiencias personalizadas para el consumidor es el neuromarketing que se describe según Lee N (2007) como la aplicación de los métodos de la neurociencia para analizar y comprender el comportamiento humano en relación con los mercados e intercambios de marketing. Donde el objetivo principal es la aplicación de hallazgos neurológicos de comportamiento de los consumidores utilizando métodos neurocientíficos. Esto varía dependiendo de los objetivos que se persigan, sin embargo, la segmentación de mercados según necesidades y preferencias es una de las más comunes y funcionales. Esto puede ser realizado mediante datos demográficos como la edad o incluso psicográficos como la

impulsividad, siendo posible identificar a los consumidores de cada segmento Sin embargo, existen otras diferencias cerebrales que no se asignan directamente ni a datos demográficos ni psicográficos (Karmakar, 2015). Este enfoque utiliza técnicas como la electroencefalografía (EEG), el eye-tracking y la respuesta galvánica para medir las reacciones del cerebro a los anuncios en tiempo real (Vásquez-Patiño & Rueda-Barrios, 2019). Estudios indican que los consumidores responden más favorablemente a estímulos que involucran varios sentidos a la vez como la vista, el oído y el olfato, generando una mayor retención del mensaje y aumentando la probabilidad de conversión en potenciales ventas. Estas estrategias sensoriales, combinadas con la personalización, permiten a las marcas generar experiencias más memorables y fortalecer la lealtad de los consumidores.

Privacidad, ética y confianza en la publicidad

Si bien el uso de la publicidad personalizada es altamente efectiva, enfrenta desafíos importantes con relación a la ética y privacidad debido al uso extensivo de datos personales. Según Boerman et al. (2021) factores que más influyen en las percepciones de los consumidores hacia la marca son el tipo de información recopilada, el intercambio de datos con terceros y las prácticas de precios personalizados, llegando al punto donde los consumidores prefieren resistirse a aquellos anuncios que utilizan información demasiado específica, como ubicación exacta o contenido altamente específico en correos electrónicos, esta situación puede llevar a valoraciones negativas de las marcas.

Otro concepto importante que considerar es la asimetría de información, que ocurre cuando las empresas poseen más conocimiento de los consumidores que estos acerca de las herramientas de personalización, existiendo una falta de transparencia que puede llevar a generar desconfianza por parte de los consumidores. Es en este punto donde la gestión de la privacidad debe tener un

perfecto equilibrio entre ofrecer beneficios relevantes y personalizados al consumidor y evitar violar las reglas de privacidad.

Desde una perspectiva ética, Boerman et al. (2021) recalca la necesidad de contratos sociales implícitos en la recolección de datos, que los consumidores “aceptan” y donde esperan que su información sea manejada de manera ética y segura. Es por ello que, si las empresas violan estas expectativas, compartiendo datos con terceros o implementando precios personalizados de manera injusta, la confianza del consumidor se ve altamente afectada de manera negativa. Es por ello la importancia de mantener un balance entre la personalización efectiva y la protección de la privacidad con el objetivo de construir relaciones de confianza a corto y largo plazos con los consumidores.

3.4 Percepción del Consumidor ante la personalización mediante Inteligencia Artificial

La creciente implementación de tecnologías basadas en inteligencia artificial (IA) en el comercio electrónico ha transformado significativamente la experiencia de compra, especialmente a través de mecanismos de personalización que permiten adaptar ofertas, contenidos y recomendaciones según las características y comportamientos individuales de los consumidores. Esta capacidad de ajustar dinámicamente la interacción con cada usuario plantea nuevas preguntas sobre cómo las personas interpretan y valoran estas experiencias mediadas por algoritmos, dando lugar a una dimensión clave en la investigación del comportamiento del consumidor: la percepción de la personalización algorítmica.

En términos generales, la percepción del consumidor en este contexto puede entenderse como la forma en que las personas interpretan, valoran y reaccionan frente al uso de sistemas automatizados que personalizan la experiencia de compra. Esta percepción se ve influida por diversos factores, tales como la confianza en la tecnología, el grado de control percibido, la transparencia del sistema y la utilidad de las recomendaciones recibidas (Lemon & Verhoef, 2016; Pizzi et al., 2021). A diferencia de los procesos de decisión tradicionales, donde el consumidor es agente principal en la búsqueda de información, en los entornos personalizados mediante IA gran parte de las opciones y contenidos se presentan filtrados, organizados o priorizados por el sistema, lo cual puede tanto facilitar la experiencia como generar inquietudes respecto a la autonomía o la manipulación (Kaplan & Haenlein, 2019).

Estudios recientes han demostrado que la aceptación y eficacia de la personalización algorítmica depende, en gran medida, de cómo el consumidor percibe la intención, competencia y neutralidad del sistema inteligente (Liao & Sundar, 2022). Asimismo, la personalización percibida como relevante y no intrusiva tiende a mejorar la satisfacción del usuario, la experiencia de compra

y la relación con la marca (Bleier y otros , 2018). Sin embargo, cuando el consumidor percibe que la personalización vulnera su privacidad o no se ajusta a sus expectativas, puede experimentar reacciones negativas como desconfianza, fatiga informativa o rechazo hacia la plataforma (Aguirre, Mahr, Grewal, de Ruyter, & Wetzels, 2015).

La forma en que los consumidores procesan la personalización mediante IA no solo impacta en su intención de compra, sino también en su disposición a repetir la experiencia, recomendarla o generar vínculos emocionales con la marca. En este sentido, la percepción positiva de la personalización puede actuar como un antecedente relevante de la satisfacción, la lealtad y el valor percibido del servicio (Tam & Ho, 2006; Xu et al., 2020). Considerar cómo los consumidores interpretan y responden a estos sistemas es, por tanto, esencial para comprender su comportamiento en entornos digitales mediados por IA.

Confianza y aceptación del consumidor hacia la IA

La confianza del consumidor es un factor determinante en la adopción de tecnologías inteligentes aplicadas a la personalización, especialmente en entornos digitales donde los sistemas operan de manera automatizada y con limitada intervención humana. En este contexto, se entiende la confianza como la creencia de que el sistema actuará de forma predecible, segura y en favor del interés del usuario, sin vulnerar su privacidad ni comprometer su autonomía (Liao & Sundar, 2022). La percepción de control, la transparencia del algoritmo, la comprensión de su funcionamiento y la protección de los datos personales son elementos clave que influyen en la aceptación del uso de inteligencia artificial para generar recomendaciones personalizadas (Aguirre et al., 2015; Pizzi et al., 2021).

Diversas investigaciones han demostrado que los consumidores tienden a aceptar más fácilmente sistemas inteligentes cuando perciben que estos proporcionan beneficios tangibles, como ahorro de tiempo, conveniencia y contenido relevante (Tam & Ho, 2006). Sin embargo, la aceptación también depende de factores psicológicos como el grado de familiaridad tecnológica del usuario, la percepción de imparcialidad del sistema y la claridad en cuanto a la finalidad de los datos recopilados (Kaplan & Haenlein, 2019). En este sentido, la confianza no solo opera como una condición de uso, sino también como un factor que media la relación entre la tecnología utilizada y la experiencia del consumidor.

Efecto de la personalización en la decisión de compra

La personalización mediante inteligencia artificial ha transformado la manera en que los consumidores toman decisiones de compra en entornos digitales. Al presentar contenidos, productos u ofertas adaptadas al perfil del usuario, la IA contribuye a reducir el esfuerzo mental, acorta el tiempo de búsqueda y genera una experiencia de compra más fluida y orientada a las necesidades individuales (Pappas, Kourouthanassis, Giannakos, & Chrissikopoulos, 2017). Esta capacidad de respuesta inmediata, basada en datos previos de navegación, intereses o comportamiento de compra, no solo incrementa la conveniencia percibida, sino que también favorece la predisposición a realizar una compra.

Cuando el consumidor percibe que las recomendaciones son útiles, novedosas y alineadas con sus intereses, se incrementa la probabilidad de que mantenga su atención en el sitio, explore alternativas y avance hacia la conversión deseada (Bleier, Harmeling & Palmatier, 2015).

La personalización en el proceso de compra no solo entrega contenido relevante, sino que también contribuye a generar emociones positivas como la satisfacción, la sorpresa o el interés, lo

que puede influir directamente en la decisión final. Por el contrario, si la personalización se percibe como excesiva, irrelevante o intrusiva, puede generar incomodidad, rechazo o incluso desconfianza hacia la marca (Kaptein & Eckles, 2012).

La efectividad de la personalización en la decisión de compra, no depende solo del grado de ajuste técnico del sistema, sino también de la manera en que el consumidor interpreta dicha experiencia. La percepción de utilidad, la variedad de opciones ofrecidas, el control percibido sobre el proceso y la claridad en la presentación de las recomendaciones son elementos clave que inciden en la calidad de la experiencia y en la disposición a concretar la compra (Bleier et al., 2015; Pappas et al., 2017).

Rol de la IA en la lealtad de la marca y satisfacción del consumidor

Incluir la inteligencia artificial en las estrategias de personalización no solo influye en el momento de la compra, sino que también puede tener efectos en el tiempo al fortalecer la satisfacción del consumidor y su relación con la marca. Una experiencia de compra positiva, caracterizada por la percepción de que las recomendaciones son pertinentes, oportunas y alineadas con los intereses personales, incrementa la probabilidad de que el consumidor se sienta valorado y comprendido, lo que favorece una evaluación positiva del servicio o producto ofrecido (Tam & Ho, 2006). Este tipo de experiencias personalizadas puede generar una conexión emocional que se traduce en actitudes favorables hacia la marca, mayor disposición a regresar y una mayor intención de recomendación.

La satisfacción del consumidor en este contexto se ve potenciada cuando la personalización no solo cumple con una función informativa o de eficiencia, sino que también contribuye a una

experiencia agradable, fluida y diferenciadora. Elementos como la estética del sitio, la narrativa visual, el lenguaje cercano o la recordación del historial de compra actúan como señales que fortalecen la percepción de cercanía y familiaridad con la marca (Bleier et al., 2018). A medida que estas interacciones generan consistencia en la experiencia del usuario, se va configurando un sentido de confianza y preferencia que puede derivar en conductas de lealtad, como la recompra o la elección recurrente frente a alternativas competidoras.

Asimismo, cuando el consumidor percibe que la personalización responde a sus necesidades sin ser invasiva, y que existe un equilibrio entre la automatización y el respeto por su privacidad, se incrementa la disposición a establecer una relación duradera con la marca (Pizzi et al., 2021). Por tanto, el uso estratégico de la inteligencia artificial en la personalización no solo busca optimizar la conversión inmediata, sino también consolidar vínculos que sostengan la fidelidad del cliente en el tiempo.

3.5 Modelos de aceptación de nuevas tecnologías

Existen modelos teóricos ampliamente reconocidos y utilizados en el campo de la adopción tecnológica que buscan explicar cómo los usuarios perciben, evalúan y aceptan nuevas herramientas y plataformas. Estos enfoques son esenciales para comprender la integración de tecnologías emergentes, como la inteligencia artificial (IA), en el comportamiento de los consumidores, permitiendo analizar cómo estas tecnologías transforman las experiencias personalizadas y las percepciones hacia las marcas:

3.5.1 Modelo de Aceptación Tecnológica (TAM)

El Modelo de Aceptación Tecnológica (TAM) propuesto por Davis (1989) se ha consolidado como herramienta clave para explicar el proceso mediante el cual los usuarios adoptan y aceptan nuevas tecnologías, donde sus dos variables principales que determinan la aceptación tecnológica corresponden a la utilidad percibida (PU) que hace referencia al grado en que el usuario cree que la tecnología mejorará su desempeño y la facilidad de uso percibida (PEOU) que es la percepción de que dicha tecnología será libre de esfuerzo.

El modelo TAM se ha utilizado en diversos estudios sobre la adopción de la inteligencia artificial aplicada en la personalización en el marketing debido a que tiene la capacidad para anticipar el comportamiento de los usuarios hacia plataformas que ofrecen este tipo de recomendaciones personalizadas, donde según sus variables principales la utilidad percibida puede reflejarse en como las recomendaciones personalizadas facilitan la toma de decisiones o ahorran tiempo, por otro lado la facilidad de uso se vincula con la fluidez de las plataformas que utilizan IA (Cataldo, 2012).

El modelo TAM ha ido evolucionando y adaptándose, incluyendo incluso nuevas variables, han surgido modelos como el TAM2 y TAM3 los cuales incluyen constructos adicionales que se relacionan con la experiencia del usuario, la calidad del sistema y la influencia social. Con estas extensiones ha quedado demostrado que, si bien el núcleo central del modelo sigue siendo el mismo, es posible mejorarlo al considerar factores específicos según su contexto de uso (Venkatesh & Davis, 2000). En el caso específico del uso de nuevas tecnologías de personalización mediante IA, podemos identificar que dependen en gran parte de variables como la confianza del consumidor y el manejo de datos personales.

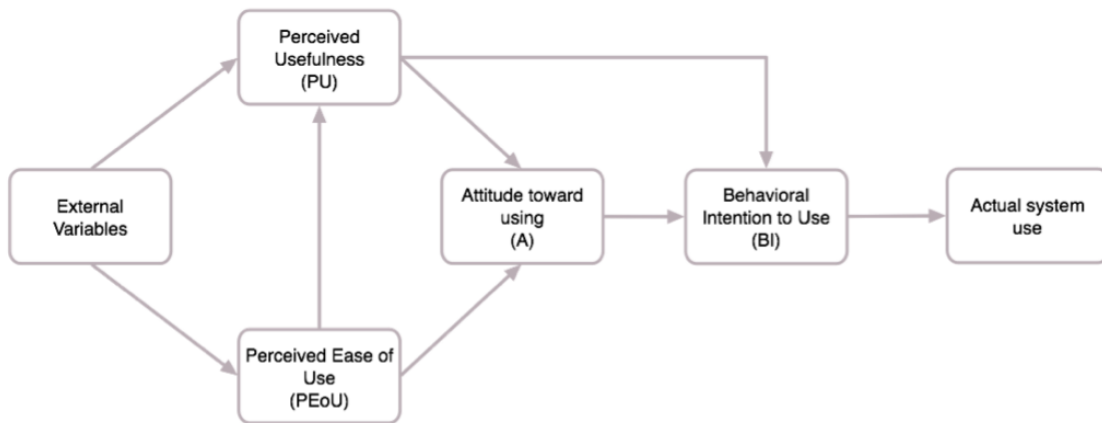


Figura 1: Modelo de Aceptación Tecnológica (TAM)

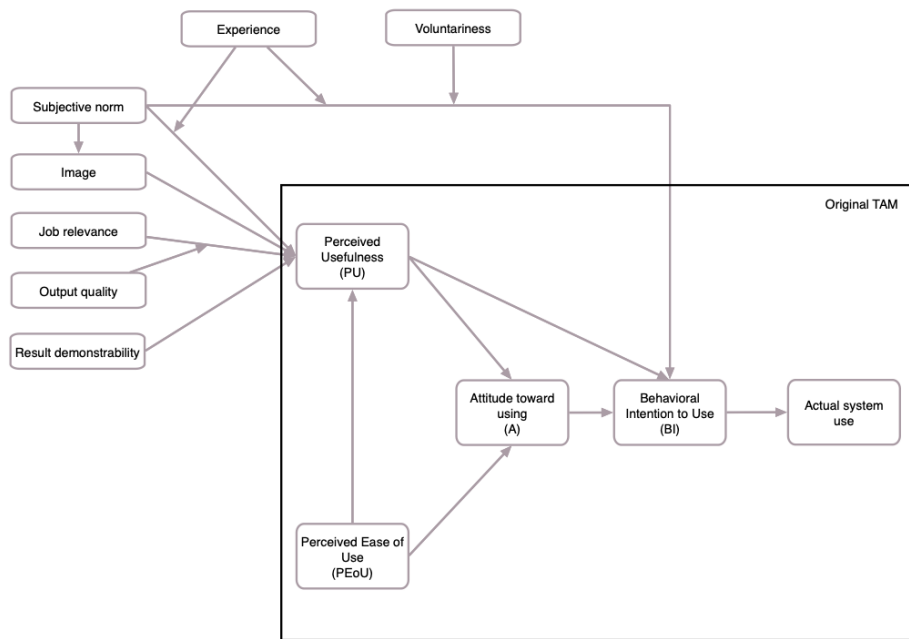


Figura 2: Modelo TAM2

Este modelo presenta tanto limitaciones como oportunidades importantes con relación a la inteligencia artificial aplicada en la personalización de anuncios. Dentro de las principales limitaciones, destaca en que el modelo TAM se enfoca principalmente en predecir la intención de uso, sin embargo, no garantiza que la adopción de esta nueva tecnología mejore el desempeño o implique un mayor nivel de satisfacción por parte del usuario. Por otro lado, TAM depende en gran medida de datos subjetivos ya que se basa en encuestas o cuestionarios, donde las respuestas reflejan percepciones personales y que no siempre coinciden con un comportamiento observado, lo cual podría introducir sesgos en los resultados obtenidos (Turner, Kitchenham, Brereton, Charters, & Budgen, 2010). Por otro lado, TAM ofrece oportunidades importantes al permitir integrar nuevos constructos tales como confianza y privacidad, los cuales serían esenciales para evaluar la adopción de sistemas basados en IA ya que los consumidores deben sentirse seguros al momento de compartir información personal para que sea tratada por IA. El modelo TAM permite capturar de forma precisa factores psicológicos y sociales que afectan la intención de uso y la percepción del consumidor.

3.5.2 Modelo Estímulo-Organismo-Respuesta (SOR)

El modelo Estímulo-Organismo-Respuesta (SOR), originalmente desarrollado desde la psicología ambiental (Mehrabian, 1974) y adaptado al ámbito del marketing (Donovan & Rossiter, 1982), constituye un marco teórico ampliamente utilizado para explicar el comportamiento del consumidor frente a estímulos del entorno. Este modelo sostiene que los estímulos externos, definidos como características del ambiente físico o digital que rodean al consumidor, generan una serie de reacciones internas en el organismo, tanto a nivel emocional como mental. Las respuestas emocionales se han explicado tradicionalmente en tres dimensiones: placer o desagrado, activación o relajación, y sensación de control o sumisión. Por otro lado, las respuestas mentales están relacionadas con procesos como la atención, la memoria, la comprensión, las creencias y las actitudes. Estas reacciones internas condicionan la respuesta observable del consumidor, la cual puede traducirse en decisiones como continuar con la compra o salir del sitio, permanencia en el sitio web, la intención de compra o el abandono del proceso. La versatilidad del modelo SOR ha facilitado su aplicación en el entorno del comercio electrónico, donde el diseño de la interfaz, la estructura del contenido, los estímulos visuales y la funcionalidad de la plataforma digital se convierten en elementos clave que inciden directamente en la experiencia de usuario (Eroglu, Machleit, & Davis, 2001). Desde esta perspectiva, la atmósfera web, entendida como el diseño consciente del entorno digital, tiene la capacidad de provocar respuestas cognitivas y emocionales que influyen en la actitud del consumidor y en su decisión de recompra (Csoban-Mirka, Esqueda-Henríquez, & Ríos, 2024).

En este contexto, la incorporación de tecnologías de inteligencia artificial (IA) en plataformas de comercio electrónico permite identificar nuevos tipos de estímulos altamente personalizados que transforman la experiencia de compra del consumidor. La inteligencia artificial, al analizar los patrones de comportamiento y las preferencias de cada usuario, entrega

recomendaciones personalizadas que funcionan como estímulos relevantes para el consumidor. Estos estímulos activan emociones positivas como el placer, la sorpresa o el interés, y también influyen en sus pensamientos y valoraciones sobre la utilidad y pertinencia de los productos sugeridos. Diversas investigaciones han evidenciado que las motivaciones emocionales y funcionales asociadas a la compra, junto con factores tecnológicos y de diseño web, influyen significativamente en variables como la actitud hacia la compra y la compra emocional, las cuales predicen la intención de recompra (Peng & Kim, 2014; Moon et al., 2017; Csoban-Mirka et al., 2024). En el caso de las marcas de moda, donde la experiencia estética, simbólica y personalizada es fundamental, la IA actúa como un estímulo estratégico que configura una atmósfera digital orientada al disfrute y la afinidad, fortaleciendo la conexión emocional con la marca e incrementando la probabilidad de conversión. En consecuencia, el modelo SOR corresponde a una base teórica adecuada para comprender cómo las recomendaciones personalizadas influyen en la forma en que los consumidores perciben su experiencia en entornos digitales actuales.

3.5.3 Validación de escalas mediante Alpha de Cronbach

El coeficiente Alpha de Cronbach constituye una de las medidas estadísticas más utilizadas para evaluar la fiabilidad interna de un instrumento de medición compuesto por múltiples ítems. Esta técnica permite estimar la consistencia interna de una escala, ya que verifica si los ítems que la componen miden de manera coherente el mismo constructo subyacente (González Alonso & Pazmiño Santacruz, 2015). Su aplicación es especialmente frecuente en investigaciones que emplean escalas tipo Likert, donde se requiere garantizar la homogeneidad de los ítems.

El valor del Alpha de Cronbach oscila entre 0 y 1, interpretándose como un indicador de la correlación media entre los ítems de una escala. Según los criterios establecidos en la teoría, un valor igual o superior a 0.7 es considerado aceptable para estudios exploratorios, mientras que valores superiores a 0.8 o 0.9 son recomendados para investigaciones que exigen mayor rigor en la medición (Quero Virla, 2010). Un Alpha elevado refleja que los ítems presentan una adecuada homogeneidad interna, mientras que un valor bajo sugiere la necesidad de revisar o eliminar aquellos ítems que no se ajustan al constructo general (González Alonso & Pazmiño Santacruz, 2015).

Diversos autores han señalado que el coeficiente Alpha de Cronbach puede verse afectado por factores como el número de ítems incluidos en la escala o la variabilidad de las respuestas, lo cual puede generar interpretaciones sesgadas al no considerar adecuadamente estos aspectos (González Alonso & Pazmiño Santacruz, 2015).

En el marco del análisis de modelos de ecuaciones estructurales (SEM), la aplicación previa del Alpha de Cronbach resulta imprescindible. Antes de proceder al modelamiento de relaciones causales entre variables latentes, es fundamental verificar que los indicadores observados presentan niveles adecuados de consistencia interna. Esta validación inicial contribuye a fortalecer la calidad del modelo propuesto y otorga mayor fiabilidad a las interpretaciones derivadas de los análisis posteriores (Quero Virla, 2010; González Alonso & Pazmiño Santacruz, 2015).

3.6 Modelos de validación estadística

En el estudio del comportamiento del consumidor y la adopción de tecnologías emergentes, el proceso de análisis no solo se limita al desarrollo teórico de modelos de aceptación, sino que debe complementarse con un modelo de validación estadística. Este enfoque permite comprobar empíricamente las relaciones planteadas, garantizando que los constructos estén definidos de manera coherente y que las interacciones entre variables puedan ser analizadas de forma rigurosa. Así, se establece un puente entre la teoría y la evidencia empírica, proporcionando herramientas para interpretar de manera precisa fenómenos complejos como la influencia de la inteligencia artificial en la personalización y percepción del consumidor.

3.6.1 Análisis Factorial Confirmatorio (CFA)

El Análisis Factorial Confirmatorio (CFA) es fundamental y se utiliza como paso a previo a Modelos de Ecuaciones Estructurales (SEM) ya que nos asegura que los constructos teóricos estén correctamente definidos. Además, ayuda a evaluar que las variables observables en el cuestionario se agrupen de manera adecuada y bajo los constructos anteriormente propuestos, validando que se encuentren de manera coherente lo que es un paso crucial antes de avanzar hacia el análisis de ecuaciones estructurales SEM donde se prueban relaciones causales entre los constructos.

El CFA es útil para validar que los ítems asociados a constructos teóricos en estudios se alineen de manera correcta con su factor correspondiente. Byrne (2016) explica que esta técnica es esencial en investigaciones donde los constructos son complejos y abstractos para garantizar la coherencia interna del modelo. Brown (2015) destaca que validar los constructos con CFA es crucial para asegurar la fiabilidad de los análisis posteriores en SEM, permitiendo así

interpretaciones significativas de las relaciones causales propuestas. En contextos donde se mide la percepción del usuario como el uso de IA aplicada a recomendaciones personalizadas, el CFA permite validar la medición de constructos claves en este ámbito como lo son la confianza y la privacidad, elementos que pueden ser considerados críticos para asegurar la fiabilidad de las conclusiones en SEM.

Al aplicar CFA se obtienen además indicadores como CFI (Comparative Fit Index) y RMSEA (Root Mean Square Error of Approximation), que evalúan el grado de ajuste del modelo. Los cuales permiten determinar si los datos se ajustan de manera correcta al marco teórico propuesto, asegurando que estos resultados sean útiles para explicar fenómenos complejos. Es por ello, que la combinación entre CFA y SEM facilita los análisis y permite explorar la interacción entre variables críticas, como lo es comprender la aceptación y el comportamiento del consumidor ante tecnologías emergentes (Brown, 2015).

3.6.2 Modelos de Ecuaciones Estructurales (SEM)

El Modelo de Ecuaciones Estructurales (SEM) es una metodología estadística avanzada que permite analizar relaciones complejas entre variables latentes y observables, combinando análisis factorial con regresión múltiple, permitiendo validar tanto los modelos de medición como las relaciones causales entre constructos (Byrne, 2016). Permitiendo evaluar de manera simultánea varios caminos causales, siendo uno de los modelos más acertados para estudios que involucran múltiples variables interrelacionadas.

La primera etapa en un modelo SEM consiste en validar los constructos teóricos a través del Análisis Factorial Confirmatorio (CFA), este paso permite asegurar que los ítems del cuestionario realizado se encuentren correctamente alineados con sus constructos

correspondientes (como confianza, satisfacción e intención de uso). Luego de que se valida esta estructura mediante CFA, se procede al modelo estructural para probar las relaciones causales entre los constructos. Por ejemplo, SEM puede analizar como la confianza en la IA afecta en la intención de uso, con la satisfacción de uso como mediador.

Por otro lado, SEM es muy valioso en investigaciones complejas ya que permite incorporar tanto moderadores como mediadores. Un moderador es una variable que altera la intensidad o dirección de relación que existe entre dos constructos, mientras que un mediador explica cómo o porque ocurre una relación. La capacidad de SEM para manejar estos tipos de relaciones permite interpretar mejor las interacciones complejas que afectan la adopción de la tecnología y el comportamiento del consumidor (Byrne, 2016; Brown, 2015).

Es por ello por lo que en investigaciones de marketing digital SEM ofrece un camino mucho más completo, ya que permite abordar simultáneamente varias rutas causales, ofreciendo modelos más precisos y comprensivos, lo que explica y refleja de mejor manera la realidad. Esta metodología nos proporciona una base sólida para la toma de decisiones, ya que asegura que los resultados sean relevantes tanto de manera teórica como práctica.

4. Modelo de investigación e hipótesis

El modelo de investigación propuesto se fundamenta en estudios previos que han explorado el impacto de la inteligencia artificial (IA) en el comportamiento del consumidor, basándose en el Modelo Estímulo-Organismo-Respuesta (SOR). Este modelo, ampliamente utilizado en las investigaciones de marketing ya que permite explicar cómo los estímulos externos (como los esfuerzos de marketing basados en IA) afectan los estados internos de los consumidores (organismo) y, posteriormente, sus conductas de consumo (respuesta). De acuerdo con investigaciones previas, el modelo SOR es particularmente efectivo para analizar la interacción entre la personalización tecnológica y la percepción del consumidor (Zhang, 2022) .

Este modelo incorpora elementos clave tales como las variables de interacción, información, accesibilidad y personalización como estímulos. Estas variables han sido ampliamente estudiadas en el contexto de la inteligencia artificial aplicada al marketing, demostrando su impacto positivo en la experiencia de marca, un constructo central que mide la relación entre los estímulos y las respuestas del consumidor, tales como la preferencia de marca y la intención de recompra (Zhang, 2022).

A continuación, se presenta el esquema del modelo de investigación, que ilustra las relaciones hipotéticas entre los estímulos, el organismo y las respuestas en el contexto del marketing digital basado en IA.

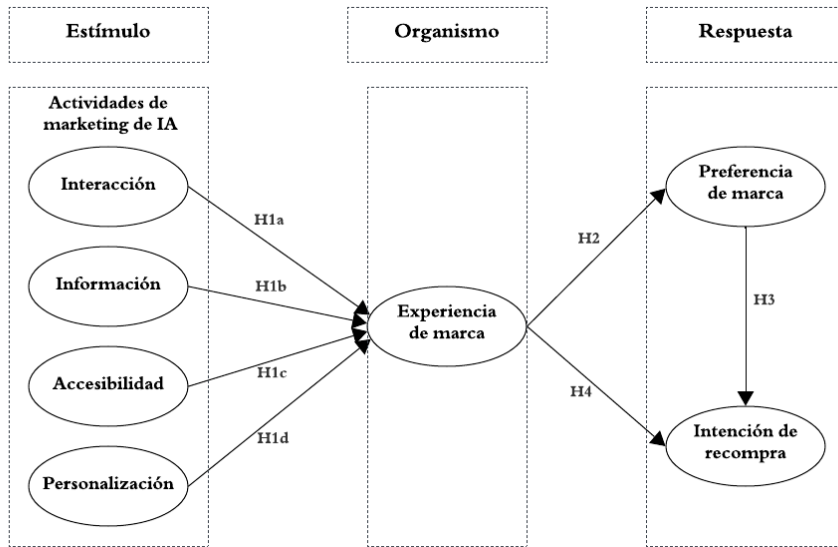


Figura 3: Modelo Estímulo-Organismo-Respuesta SOR (Elaboración propia)

4.1 Interacción

La interacción se refiere a la capacidad de la tecnología para facilitar una comunicación efectiva e interactiva entre la marca y el consumidor. Este constructo evalúa cómo los consumidores perciben la calidad de sus interacciones, donde se encuentran incluidas respuestas personalizadas y atención receptiva. En el modelo SOR, la interacción actúa como un estímulo clave que afecta las percepciones internas del consumidor y, finalmente, su comportamiento de compra (Mehrabian, 1974; Zhang et al., 2022).

En el contexto de la moda, la interacción mediante tecnologías de IA permite a los consumidores obtener información precisa, relevante y actualizada sobre productos disponibles, colecciones y tendencias. Mejorando así la percepción de cercanía y atención al cliente lo cual contribuye a fortalecer la experiencia de marca y fomenta relaciones más sólidas y duraderas con los consumidores (Donovan & Rossiter, 1982; Ha & Lennon, 2010).

H1a: La interacción proporcionada por la IA está positivamente relacionada con la experiencia de marca.

4.2 Información

La información hace referencia a la relevancia, utilidad y claridad de los datos proporcionados al consumidor por tecnologías de IA. Este constructo incluye elementos como la capacidad de la tecnología para ofrecer recomendaciones personalizadas y datos que faciliten la toma de decisiones para los consumidores. En el modelo SOR, la información actúa como un estímulo que fomenta respuestas positivas al proporcionar un valor percibido más alto (Eroglu et al., 2001; Zhang et al., 2022).

En la industria de la moda, la información personalizada permite a los consumidores mantenerse al día respecto tanto a tendencias, eventos e información y realizar compras más informadas. Mejorando tanto la experiencia de compra y a su vez, posicionando a las marcas como innovadoras y centradas en las necesidades del cliente (Gómez Suárez & Rozano Sáez, 2015).

H1b: La información proporcionada por la IA está positivamente relacionada con la experiencia de marca.

4.3 Accesibilidad

La accesibilidad busca medir la facilidad con la que los consumidores pueden acceder a servicios o información a través de plataformas basadas en IA. Esto incluye factores como disponibilidad constante, rapidez en las respuestas y facilidades de uso. Dentro del modelo SOR, la accesibilidad se considera un estímulo que mejora la experiencia del consumidor al eliminar barreras y facilitar la interacción (Mehrabian & Russell, 1974; Richard, 2005).

En el contexto de la moda, la accesibilidad permite a los consumidores obtener asistencia inmediata y eficiente, desde cualquier lugar, sobre disponibilidad de productos, tallas, devoluciones o preguntas frecuentes. Esta facilidad de acceso fortalece la percepción de las marcas como confiables y centradas en el cliente (Donovan & Rossiter, 1982; Ha & Lennon, 2010).

H1c: La accesibilidad facilitada por la IA está positivamente relacionada con la experiencia de marca.

4.4 Personalización

La personalización se refiere a la capacidad de las plataformas de IA para adaptar su contenido y recomendaciones a las necesidades y preferencias individuales de los consumidores. Este constructo es un estímulo fundamental en el modelo SOR, ya que aumenta la percepción de valor y satisfacción al ofrecer experiencias únicas y relevantes (Zhang et al., 2022; Richard, 2005).

En la moda, la personalización es crucial, ya que permite a los consumidores sentirse entendidos y valorados por las marcas. Por ejemplo, a través de recomendaciones de estilos, colores o combinaciones de prendas basadas en preferencias individuales según el comportamiento pasado de los consumidores, generando así una mayor conexión emocional y fidelidad hacia la marca (Gómez Suárez & Rozano Sáez, 2015).

H1d: La personalización ofrecida por la IA está positivamente relacionada con la experiencia de marca.

4.5 Experiencia de marca

La experiencia de marca incluye las percepciones, emociones y respuestas cognitivas del consumidor al interactuar con la marca. En el modelo SOR, este constructo representa el organismo, ya que se encuentra en el centro del modelo, mediando la relación entre los estímulos (interacción, información, accesibilidad y personalización) y las respuestas conductuales del consumidor. Una experiencia de marca positiva refuerza la conexión emocional con la marca, lo que puede derivar en preferencia y lealtad (Mehrabian & Russell, 1974; Donovan & Rossiter, 1982).

En la moda, una experiencia de marca enriquecedora puede incluir elementos como la capacidad de una IA para recomendar productos, resolver problemas rápidamente y alinear los valores de la marca con los del consumidor. Esto crea un vínculo emocional más fuerte y duradero (Ha & Lennon, 2010).

H2: La experiencia de marca está positivamente relacionada con la preferencia de marca.

H4: La experiencia de marca está positivamente relacionada con la intención de recompra

4.6 Preferencia de marca

La preferencia de marca refleja la inclinación del consumidor hacia una marca específica, basada en percepciones positivas derivadas de sus interacciones y experiencias pasadas. Este constructo es una respuesta conductual en el modelo SOR que indica el nivel de compromiso y lealtad hacia la marca (Zhang et al., 2022; Richard, 2005).

En la moda, la preferencia de marca se vincula directamente con la capacidad de las tecnologías de IA para ofrecer experiencias personalizadas y relevantes, posicionando a las marcas que emplean estas herramientas como líderes en innovación y atención al cliente (Donovan & Rossiter, 1982; Gómez Suárez & Rozano Sáez, 2008).

H3: La preferencia de marca está positivamente relacionada con la intención de recompra.

4.7 Intención de recompra

La intención de recompra se refiere a la disposición del consumidor para realizar futuras compras en la misma marca. Este constructo es una respuesta conductual final en el modelo SOR, influenciada por los estímulos (interacción, información, accesibilidad y personalización) y mediada por la experiencia de marca (Mehrabian & Russell, 1974; Zhang et al., 2022).

En el sector de la moda, la intención de recompra refleja la efectividad de las estrategias de personalización basadas en IA. Los consumidores que experimentan un alto nivel de satisfacción con una marca están más inclinados a mantener una relación a largo plazo y repetir compras en el futuro (Ha & Lennon, 2010).

H5a: La experiencia de marca media la relación entre los esfuerzos de marketing basados en IA y la preferencia de marca.

H5b: La experiencia de marca media la relación entre los esfuerzos de marketing basados en IA y la intención de recompra

5. Metodología

5.1 Muestra

Los datos utilizados para llevar a cabo este estudio se obtuvieron a partir de las respuestas recopiladas mediante una encuesta desarrollada a través de SurveyMonkey. La encuesta fue diseñada con el objetivo de recolectar información sobre las percepciones y el comportamiento de los consumidores en relación con el impacto de la inteligencia artificial en la personalización de recomendaciones de compra en marcas de moda. Este cuestionario permitió explorar cómo las estrategias basadas en IA influyen en la percepción del consumidor y su interacción con las distintas marcas de la industria.

La difusión del cuestionario se realizó a través de diferentes canales, incluyendo canales online como diversas redes sociales para llegar a personas de diversas regiones del país, esto con el fin de alcanzar un número adecuado de participantes y garantizar que la muestra sea representativa. Sin embargo, para minimizar el sesgo que pudiese existir y ampliar la diversidad de los encuestados, también se implementó la estrategia de distribuir códigos QR en diversos centros comerciales ubicados en distintas comunas de Santiago. Este enfoque permitió captar a consumidores habituales de moda que representan al público objetivo del estudio.

La encuesta incluyó preguntas diseñadas para evaluar la interacción, información, accesibilidad, personalización, experiencia de marca, preferencia de marca e intención de recompra, siguiendo el modelo SOR como marco teórico. Estas preguntas fueron formuladas con el objetivo de entender cómo los estímulos proporcionados por la inteligencia artificial influyen en las percepciones internas y en las respuestas conductuales de los consumidores.

5.2 Cuestionario

Para llevar a cabo este estudio, se diseñó un cuestionario dividido en cuatro secciones principales, desarrollado a través de SurveyMonkey. Este instrumento fue diseñado para recopilar datos clave sobre las percepciones de los consumidores, sus hábitos de compra, el impacto de la inteligencia artificial en la personalización de recomendaciones de compra en marcas de moda y datos demográficos. El cuestionario se estructuró de la siguiente forma:

5.2.1 Términos y condiciones de participación

Antes de iniciar el cuestionario, los participantes debían aceptar los términos y condiciones, otorgando su consentimiento informado para el uso de los datos recopilados exclusivamente con fines académicos. Esta sección garantizó que los encuestados comprendieran la confidencialidad de la información proporcionada y los objetivos del estudio. Culminando con la pregunta ¿Aceptas participar en esta encuesta?, donde solo se podía continuar si la respuesta era positiva. Además, se agregó una casilla para ingresar el correo electrónico de forma opcional.

5.2.2 Hábitos de compra y frecuencia de uso de redes sociales

Esta segunda sección incluyó preguntas destinadas a evaluar los hábitos de consumo de los participantes y su interacción con las redes sociales. Esta parte permitió obtener una visión general sobre la frecuencia de compra de productos de moda, los canales utilizados para realizar compras, y el tiempo promedio dedicado a las redes sociales. En base, se realizaron el siguiente tipo de preguntas:

Medición
¿Cuál es tu género?
¿En qué rango de edad te encuentras?
¿Cuál es el ingreso mensual promedio de tu hogar?
¿Cuál es tu nivel más alto de educación?
¿Con cuáles de las siguientes marcas de moda has interactuado utilizando herramientas de IA (como recomendaciones personalizadas, chatbots, etc.)? (Selecciona todas las que correspondan)

Tabla 1: Encuesta sobre hábitos de consumo (Elaboración propia)

5.2.3 Constructos

En la tercera sección, el cuestionario se subdividió en siete partes, donde cada una representaba a los constructos principales del modelo teórico: interacción, información, accesibilidad, personalización, experiencia de marca, preferencia de marca e intención de recompra. Cada constructo fue medido mediante una serie de ítems que se basaron en una escala de Likert de cinco puntos, donde los participantes indicaron su nivel de acuerdo o desacuerdo con cada afirmación. Esto permitió obtener percepciones más matizadas y establecer un grado de aceptación sobre las variables analizadas. En base a esto las preguntas se estructuran de la siguiente forma:

Constructo	Ítem	Medición
Interacción	INT1	Se ajusta a mis necesidades de moda en el momento en que recibo la publicidad.
	INT2	Proporciona respuestas claras y útiles a mis preguntas sobre productos de moda.
	INT 3	Me ofrece atención personalizada, adaptándose a mis preferencias individuales.
Información	INF1	Me ayuda a entender tendencias y eventos importantes en el mundo de la moda.
	INF2	Proporciona recomendaciones útiles sobre productos que coinciden con mis intereses.
	INF3	Ofrece información relevante que facilita mis decisiones de compra.
Accesibilidad	ACC1	Proporciona respuestas más oportunas.
	ACC2	Es conveniente y eficiente en la entrega de información.
	ACC3	Ofrece asistencia inmediata o información digital eficiente.
	ACC4	Responde de manera inmediata a mis consultas, en cualquier momento y en cualquier lugar.
Personalización	CUS1	Siento que el uso de IA satisface mis necesidades personales y preferencias de estilo.
	CUS2	Cuando tengo un problema, la IA muestra un interés sincero en resolver mis dudas o inquietudes.
	CUS3	Confío en que tiene la capacidad de realizar el trabajo de recomendarme los productos adecuados.
Experiencia de marca	BE1	Disfruto interactuar con este tipo de publicidad de las marcas de moda.
	BE2	La experiencia al interactuar con publicidad de marcas de moda fue interesante y satisfactoria.
	BE3	Estoy satisfecho con la experiencia general que ofrecen las marcas de moda.
	BE4	Me siento feliz al interactuar con publicidad realizada por estas marcas.
	BE5	Estas marcas ofrecen procesos "interactivos" que enriquecen mi experiencia.
Preferencias de marca	BP1	Las marcas que utilizan esta tecnología están entre las mejores en la industria de la moda.
	BP2	Estoy muy satisfecho con estas las marcas que utilizan esta tecnología.
	BP3	Las marcas que utilizan esta tecnología son altamente profesionales en atender mis necesidades.
	BP4	Considero que las marcas que utilizan esta tecnología son superiores a sus competidoras.
	BP5	Las marcas que utilizan esta tecnología son mis preferidas sobre cualquier otra.
	BP6	Cuando se trata de realizar una compra, prefiero las marcas que utilizan esta tecnología.
Intención de recompra	RI1	Espero mantener mi relación con estas marcas a largo plazo.
	RI2	Definitivamente tengo la intención de seguir comprando en estas marcas.
	RI3	Estoy dispuesto a comprar más productos de estas marcas en el futuro.
	RI4	Si estas marcas lo solicitan, estaría dispuesto a hacer una mayor inversión para apoyarlas.
	RI5	Volveré a comprar productos de estas marcas.

Tabla 2: Encuesta sobre constructos (Elaboración propia)

5.2.4 Datos demográficos

Finalmente, la cuarta sección recopiló información demográfica básica de los participantes, como edad, género, nivel educacional, ocupación e ingresos mensuales. Esta información permitió segmentar la muestra y analizar posibles diferencias en las percepciones y comportamientos en función de estas variables.

Medición
¿Cuál es tu género?
¿En qué rango de edad te encuentras?
¿Cuál es el ingreso mensual promedio de tu hogar?
¿Cuál es tu nivel más alto de educación?
¿Con cuáles de las siguientes marcas de moda has interactuado utilizando herramientas de IA (como recomendaciones personalizadas, chatbots, etc.)? (Selecciona todas las que correspondan)

Tabla 3: Encuesta datos demográficos (Elaboración propia)

5.3 Análisis de datos

El análisis de los datos recopilados en el presente estudio contempló dos etapas principales. La primera consistió en la evaluación de la fiabilidad interna de las escalas mediante la aplicación del coeficiente Alpha de Cronbach. Esta evaluación permitió verificar la consistencia interna de los ítems que conforman cada uno de los constructos del modelo teórico adoptado. Posteriormente, se implementó un análisis de modelos de ecuaciones estructurales (SEM) con el objetivo de validar el modelo conceptual propuesto y examinar las relaciones directas e indirectas entre las variables latentes.

5.3.1 Análisis de fiabilidad interna mediante Alpha de Cronbach

La fiabilidad interna de las escalas utilizadas en el instrumento de medición fue evaluada mediante el coeficiente Alpha de Cronbach, técnica ampliamente reconocida en investigaciones de ciencias sociales por su capacidad para estimar la consistencia interna de los ítems que miden un mismo constructo (González Alonso & Pazmiño Santacruz, 2015; Quero Virla, 2010). El análisis fue realizado utilizando el software SPSS versión 29.0.1.1. Para la interpretación de los resultados se consideraron los criterios establecidos en la literatura, determinando como aceptables los valores de Alpha de Cronbach iguales o superiores a 0.7 para estudios exploratorios, y superiores a 0.8 para investigaciones que requieren alta fiabilidad (Quero Virla, 2010). Esta validación permitió confirmar la consistencia de las escalas antes de proceder con el análisis estructural.

5.3.1 Modelamiento de ecuaciones estructurales (SEM)

Una vez validada la fiabilidad interna de las escalas, se desarrolla el análisis de modelos de ecuaciones estructurales (SEM) con el objetivo de validar el modelo conceptual propuesto y examinar las relaciones entre las variables latentes. Este procedimiento fue ejecutado mediante el software SPSS Amos 30.0.0.

El modelo teórico, fundamentado en el enfoque Estímulo-Organismo-Respuesta (S-O-R), permitió analizar tanto los efectos directos como indirectos entre los constructos considerados, siguiendo lineamientos metodológicos previos en el estudio del comportamiento del consumidor en entornos digitales (Eroglu, Machleit, & Davis, 2001; Peng & Kim, 2014).

La evaluación de la bondad de ajuste del modelo estructural consideró múltiples índices complementarios, tales como el Comparative Fit Index (CFI), Tucker-Lewis Index (TLI), Root Mean Square Error of Approximation (RMSEA) y Standardized Root Mean Square Residual (SRMR). La elección de estos indicadores responde a la necesidad de capturar distintas dimensiones del ajuste del modelo, como la calidad de replicación y el error de aproximación, siguiendo criterios establecidos en la investigación metodológica (Hu & Bentler, 1999). Se consideraron como aceptables valores de CFI y TLI superiores a 0.90, un RMSEA inferior a 0.08 y un SRMR inferior a 0.08.

6. Resultados y análisis

Se emplearon los softwares IBM SPSS Statistics 29.0.1.1 y SPSS Amos 30.0.0 para llevar a cabo el análisis de los datos y obtener los resultados. Con SPSS Statistics se realizaron análisis descriptivos relevantes, mientras que SPSS Amos permitió ejecutar el análisis confirmatorio a través de Modelos de Ecuaciones Estructurales (SEM).

De un total inicial de 224 respuestas obtenidas en la encuesta, se llevó a cabo un proceso de depuración de la base de datos. Este proceso consistió en eliminar respuestas incompletas o que no aportaban información significativa para el análisis del modelo. Como resultado, se obtuvieron 175 respuestas válidas, las cuales fueron utilizadas para el análisis.

6.1 Perfil demográfico de los encuestados

Inicialmente, se realizó un análisis de frecuencia básico en SPSS con el objetivo de describir y comprender las características generales de los encuestados. Este análisis inicial se centró en las variables demográficas, como edad, género, nivel educativo y nivel de ingresos, además, se incluyó una pregunta de preferencias de marca con el propósito de identificar patrones y obtener una visión clara de cómo se compone la muestra.

6.1.1 Género

De un total de 175 encuestados, el 62,3% se identifica con el género femenino y el 37,7% como masculino, evidenciando una mayor representación de mujeres en la muestra. Este dato es relevante para analizar cómo la percepción de las recomendaciones personalizadas generadas por inteligencia artificial puede diferir entre géneros dentro de las distintas marcas de moda.

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Masculino	66	37.7	37.7	37.7
	Femenino	109	62.3	62.3	100.0
	Total	175	100.0	100.0	

Tabla 4: Porcentaje de género femenino y masculino en la muestra(Elaboración propia)

A continuación se puede apreciar de manera gráfica la diferencia porcentual entre el género de los encuestados:




Gráfico 1: Género de los encuestados(Elaboración propia)

6.1.2 Edad

En cuanto a rango etario, la mayoría de los encuestados se encuentra en el rango de 18 a 24 años (42,3%), seguido por los grupos de 25 a 34 años(20,0%) y 35 a 44 años (17,1%). Estos tres segmentos representan la mayoría de la muestra con un 79,4%, destacando una mayor concentración en consumidores jóvenes y adultos jóvenes, quienes son el público objetivo principal de las marcas de moda y las estrategias de personalización digital.

Por otro lado, los rangos de los extremos, es decir, tanto los rangos de mayor edad como los de menor edad tienen una representación menor, con un 9,1% en el grupo de 45 a 54 años, 4,0% en 55 a 64 años y 4,6% en 65 años o más. Por su parte, los menores de 18 años representan solo el 2,9% de los encuestados.

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Menos de 18 años	5	2.9	2.9	2.9
	18-24 años	74	42.3	42.3	45.1
	25-34 años	35	20.0	20.0	65.1
	35-44 años	30	17.1	17.1	82.3
	45-54 años	16	9.1	9.1	91.4
	55-64 años	7	4.0	4.0	95.4
	65 años o más	8	4.6	4.6	100.0
	Total	175	100.0	100.0	

Tabla 5: Porcentaje de grupos etarios de la muestra(Elaboración propia)

A continuación, se presenta de manera gráfica la distribución de los resultados previamente descritos, permitiendo visualizar la concentración de los encuestados en cada rango etario:




Gráfico 2: Grupo etario de los encuestados (Elaboración propia)

6.1.3 Ingresos

El rango de ingreso con mayor participación en la muestra corresponde a los encuestados que reciben un ingreso entre \$500,001 y \$1,000,000 CLP, constituyendo el 28,6% de la muestra total. Este grupo es seguido por los rangos de \$1,000,001 a \$1,500,000 CLP con un 17,1% y menos de \$300,000 CLP con un 14,3%.

Por otro lado, el rango con los ingresos más altos, es decir, los que superan los \$3,000,000 CLP, representan el 8,0% de los encuestados, observándose una menor participación de consumidores de altos ingresos en esta muestra.

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Menos de \$300,000 CLP	25	14.3	14.3	14.3
	\$300,001 a \$500,000 CLP	20	11.4	11.4	25.7
	\$500,001 a \$1,000,000 CLP	50	28.6	28.6	54.3
	\$1,000,001 a \$1,500,000 CLP	30	17.1	17.1	71.4
	\$1,500,001 a \$2,000,000 CLP	17	9.7	9.7	81.1
	\$2,000,001 a \$3,000,000 CLP	19	10.9	10.9	92.0
	Más de \$3,000,000 CLP	14	8.0	8.0	100.0
	Total	175	100.0	100.0	

Tabla 6: Porcentaje de Ingreso promedio de la muestra (Elaboración propia)

A continuación, en el gráfico se observa la distribución de los ingresos de los encuestados, destacando que el rango de \$500,001 a \$1,000,000 CLP concentra el mayor porcentaje, seguido por los rangos medios y bajos:




Gráfico 3: Ingreso promedio de los encuestados (Elaboración propia)

6.1.4 Educación

Es posible identificar que la mayor parte de los encuestados tiene educación universitaria (54,3%), seguida por aquellos con educación técnica o profesional (20,0%) y educación media completa (16,0%). Los niveles más altos, como postgrados (magíster o doctorado), representan solo el 4,0%, mientras que los niveles educativos más bajos, como sin educación formal, educación básica completa o otro, constituyen en conjunto un 5,7%.

Esta distribución puede estar influenciada por el contexto de la investigación, ya que, al tratarse de una tesis universitaria, es probable que la muestra esté sesgada hacia individuos con dicho nivel de educación, debido a los canales de distribución utilizados para obtener la muestra.

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Otro	6	3.4	3.4	3.4
	Sin educación formal	1	.6	.6	4.0
	Educación básica completa	3	1.7	1.7	5.7
	Educación media completa	28	16.0	16.0	21.7
	Educación técnica o profesional	35	20.0	20.0	41.7
	Educación universitaria	95	54.3	54.3	96.0
	Postgrado (magíster, doctorado)	7	4.0	4.0	100.0
	Total	175	100.0	100.0	

Tabla 7: Porcentaje de nivel educacional de encuestados (Elaboración propia)

De manera gráfica es posible observar con mayor claridad la inclinación de los resultados hacia un nivel de educación universitaria seguida por educación técnica profesional, destacando por sobre las otras alternativas:




Gráfico 4: Nivel educacional de los encuestados (Elaboración propia)

6.2 Comportamiento del consumidor

El grupo más grande de consumidores compra productos de moda cada 2-3 meses (29.7%), seguido por quienes lo hacen una vez al mes (24.0%). Esto indica que más de la mitad de los encuestados mantiene un hábito de compra relativamente frecuente. Además, se observa que un 20.6% compra más de una vez al mes, representando a los consumidores más activo. Por otro lado, el 15.4% realiza compras cada seis meses y solo un 10.3% lo hace menos de una vez al año, evidenciando un segmento minoritario con menor interés o capacidad de compra.

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Más de una vez al mes	36	20.6	20.6	20.6
	Una vez al mes	42	24.0	24.0	44.6
	Cada 2-3 meses	52	29.7	29.7	74.3
	Cada 6 meses	27	15.4	15.4	89.7
	Menos de una vez al año	18	10.3	10.3	100.0
	Total	175	100.0	100.0	

Tabla 8: Porcentaje frecuencia de compra de encuestados (Elaboración propia)

Se realizó un análisis de frecuencia básico en SPSS para examinar las variables relacionadas con el comportamiento del consumidor. Este análisis incluyó aspectos clave como los hábitos de compra y la frecuencia de uso de redes sociales. El propósito de este análisis es describir la distribución general de estas variables, identificando patrones iniciales que permitan caracterizar el comportamiento de los encuestados en relación con sus preferencias de consumo y su interacción en plataformas digitales.

6.2.1 ¿Con qué frecuencia compras productos de moda?

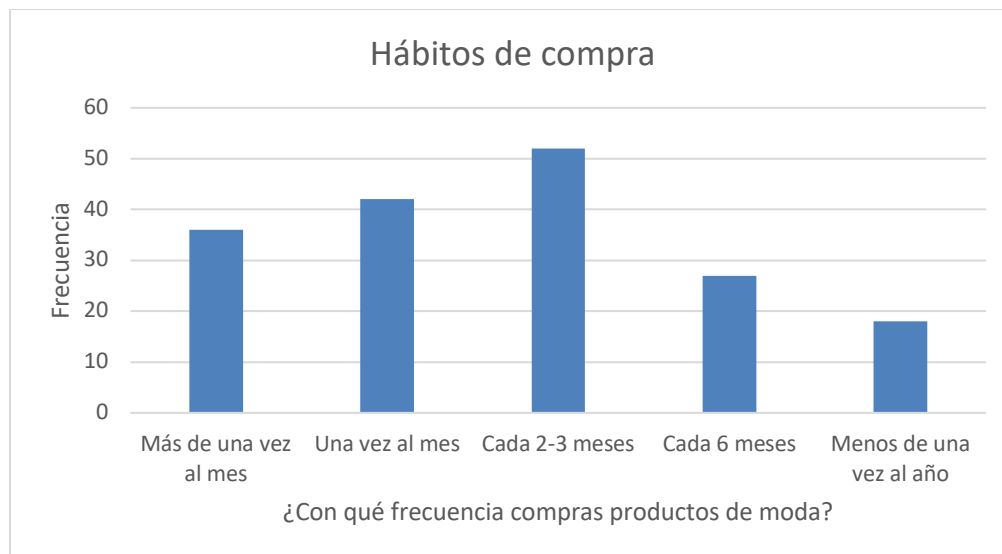


Gráfico 5: Frecuencia de compra de los encuestados (Elaboración propia)

6.2.2 ¿Dónde realizas la mayoría de tus compras de moda?

La mayoría de los consumidores (38.9%) combina compras en tiendas físicas y en línea, lo que refleja una preferencia por la flexibilidad en los canales de compra. Un 29.7% prefiere principalmente tiendas en línea, mientras que un 19.4% opta mayormente por tiendas físicas. Aunque solo un 10.3% compra exclusivamente en tiendas físicas y un 1.7% únicamente en línea, todas estas decisiones pueden estar influenciadas en distintos niveles por las recomendaciones personalizadas, ya sea a través de plataformas digitales o mediante la percepción que el consumidor tiene de ellas antes de concretar su compra.

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Exclusivamente en tiendas físicas	18	10.3	10.3	10.3
	Principalmente en tiendas físicas	34	19.4	19.4	29.7
	Ambos por igual	68	38.9	38.9	68.6
	Principalmente en tiendas en línea	52	29.7	29.7	98.3
	Exclusivamente en tiendas en línea	3	1.7	1.7	100.0
	Total	175	100.0	100.0	

Tabla 10: Porcentaje canal de compra de encuestados (Elaboración propia)




Gráfico 6: Canal de compra de los encuestados (Elaboración propia)

6.2.3 ¿Cuál es el gasto promedio en una compra de moda?

La mayoría de los consumidores gasta un promedio entre \$20.001 y \$40.000 CLP por compra (42.9%), seguido por un 23.4% que utiliza entre \$40.001 y \$60.000 CLP. Solo un 12.6% supera los \$80.000 CLP, mientras que un 11.4% se encuentra en el rango de \$60.001 a \$80.000 CLP. Minoritariamente un 9.7% gasta menos de \$20.000 CLP, lo que indica que la mayoría de los consumidores invierte una cantidad moderada en moda. Esto puede ser debido a la influencia de diversos factores tales como el nivel de ingresos y la exposición a recomendaciones personalizadas, que pueden incentivar un mayor gasto en ciertos segmentos.

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Menos de \$20.000 CLP	17	9.7	9.7	9.7
	\$20.001 a \$40.000 CLP	75	42.9	42.9	52.6
	\$40.001 a \$60.000 CLP	41	23.4	23.4	76.0
	\$60.001 a \$80.000 CLP	20	11.4	11.4	87.4
	Más de \$80.000 CLP	22	12.6	12.6	100.0
	Total	175	100.0	100.0	

Tabla 11: Porcentaje gasto promedio de compra de encuestados (Elaboración propia)




Gráfico 7: Gasto promedio de compra de encuestados (Elaboración propia)

6.2.4 ¿Con qué frecuencia utilizas redes sociales? (por ejemplo, Instagram, Facebook, TikTok, Pinterest, X (antes Twitter), YouTube, entre otras)

Un 93.1% de los encuestados utiliza redes sociales varias veces al día, lo que confirma su relevancia en la vida cotidiana de los consumidores. La minoría con un 1.7% las usa una vez al día y un 3.4% varias veces a la semana, mientras que menos del 2% no las utiliza. Este alto nivel de interacción con plataformas digitales y redes sociales refuerza la importancia de las recomendaciones personalizadas en redes sociales y su impacto en las decisiones de compra.

	Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Varias veces al día	163	93.1	93.1
	Una vez al día	3	1.7	94.9
	Varias veces a la semana	6	3.4	98.3
	Una vez a la semana o menos	1	.6	98.9
	No uso redes sociales	2	1.1	100.0
	Total	175	100.0	100.0

Tabla 11: Porcentaje de uso de redes sociales de encuestados (Elaboración propia)




Gráfico 8: Uso de redes sociales de encuestados (Elaboración propia)

6.2.5 ¿Qué tan seguido interactúas (haciendo clic, guardando, enviando, compartiendo, etc) con anuncios dirigidos en redes sociales relacionados con moda?

Más de la mitad de los encuestados interactúa frecuentemente con anuncios dirigidos en redes sociales relacionados con moda, ya sea "siempre" (22.9%) o "a menudo" (28.6%). Un 27.4% lo hace "ocasionalmente", lo que indica que la mayoría de los consumidores presta atención a este tipo de contenido en algún grado. Solo un 16.0% interactúa "rara vez" y un 5.1% nunca lo hace, mostrando que la exposición a estos anuncios es alta y que pueden influir en distintas etapas del proceso de compra.

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Siempre	40	22.9	22.9	22.9
	A menudo	50	28.6	28.6	51.4
	Ocasionalmente	48	27.4	27.4	78.9
	Rara vez	28	16.0	16.0	94.9
	Nunca	9	5.1	5.1	100.0
	Total	175	100.0	100.0	

Tabla 12: Porcentaje de interacción con anuncios de encuestados (Elaboración propia)




Gráfico 9: Interacción con anuncios de encuestados (Elaboración propia)

6.2.6 ¿Qué tan relevante consideras la personalización de los anuncios de moda que ves en redes sociales?

La mayoría de los encuestados considera que la personalización de los anuncios de moda en redes sociales es relevante, con un 34.9% que la percibe como "muy relevante" y un 45.1% como "algo relevante", con un total de 80% de respuestas positivas. Solo un 15.4% la encuentra "poco relevante" y un 4.6% "nada relevante". Esto sugiere que la personalización tiene un impacto significativo en la percepción del consumidor.

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Muy relevante	61	34.9	34.9	34.9
	Algo relevante	79	45.1	45.1	80.0
	Poco relevante	27	15.4	15.4	95.4
	Nada relevante	8	4.6	4.6	100.0
	Total	175	100.0	100.0	

Tabla 13: Porcentaje de relevancia de personalización en anuncios de encuestados (Elaboración propia)

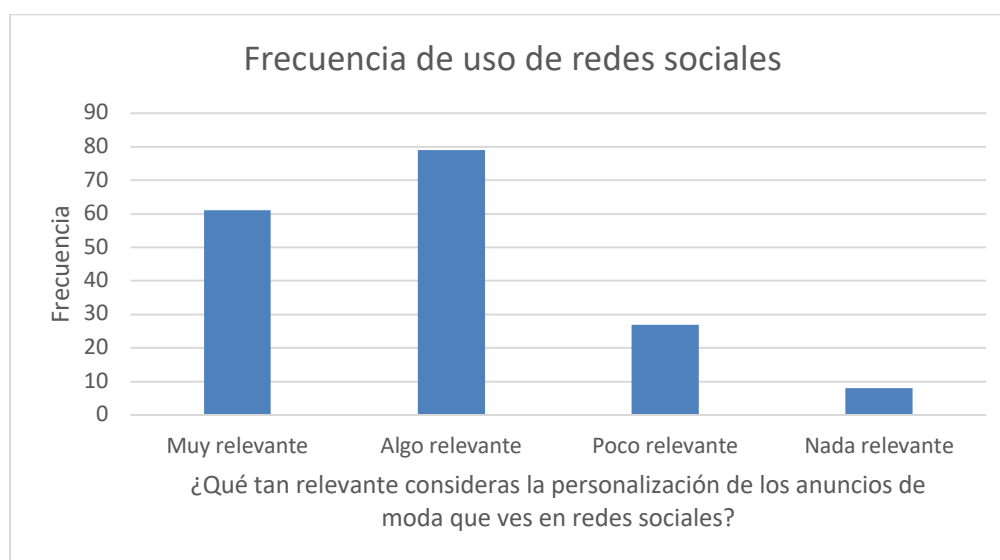


Gráfico 10: Relevancia de personalización en anuncios de encuestados (Elaboración propia)

6.2.7 Marcas de moda has interactuado utilizando herramientas de IA

		Respuestas		Porcentaje de casos
		N	Porcentaje	
Interacción marcas de moda	Falabella	138	22.5%	82.6%
	Paris	86	14.0%	51.5%
	Ripley	82	13.4%	49.1%
	H&M	67	10.9%	40.1%
	Zara	29	4.7%	17.4%
	Nike	57	9.3%	34.1%
	Adidas	53	8.6%	31.7%
	Shein	66	10.7%	39.5%
	Dafiti	36	5.9%	21.6%
	Total	614	100.0%	367.7%

Tabla 14: Porcentaje de marcas de moda con las que han interactuado los encuestados
(Elaboración propia)

6.3 Fiabilidad de constructos

Con el objetivo de evaluar la consistencia interna de los constructos utilizados en el modelo teórico, se aplicó el coeficiente Alpha de Cronbach a cada uno de ellos, utilizando el software SPSS. Este estadístico permite medir la fiabilidad de los ítems que componen una escala, es decir, el grado en que los ítems son consistentes entre sí al evaluar un mismo concepto o dimensión. Según los criterios establecidos por Loewenthal (1996), un valor igual o superior a 0,60 es considerado aceptable para escalas que incluyen menos de 10 ítems, mientras que George y Mallery (2003) sugieren que valores superiores a 0,70 indican una buena fiabilidad.

La **Tabla 15** muestra los valores obtenidos para cada constructo, los cuales fueron calculados considerando la totalidad de los ítems que los componen.

Constructo	Ítems	Alpha de Cronbach
Interacción(INT)	INT1	0,759
	INT2	
	INT 3	
Información(INF)	INF1	0,789
	INF2	
	INF3	
Accesibilidad(ACC)	ACC1	0,852
	ACC2	
	ACC3	
	ACC4	
Personalización(CUS)	CUS1	0,860
	CUS2	
	CUS3	
Experiencia de marca(BE)	BE1	0,886
	BE2	
	BE3	
	BE4	
	BE5	
Preferencia de marca(BP)	BP1	0,880
	BP2	
	BP3	
	BP4	
	BP5	
	BP6	
Intención de recompra(RI)	RI1	0,902
	RI2	
	RI3	
	RI4	
	RI5	

Tabla 15: Resultados de la fiabilidad de los constructos a través de los coeficientes de Alpha de Cronbach

Los resultados evidencian una alta consistencia interna para todos los constructos evaluados, ya que todos los coeficientes Alpha de Cronbach se encuentran por sobre el umbral de 0,70. El constructo con el valor más bajo fue “Interacción” (0,759), mientras que el más alto correspondió a “Intención de recompra” (0,902). Estos niveles de fiabilidad sugieren que los ítems utilizados para cada dimensión del modelo miden de manera coherente los conceptos propuestos y permiten continuar con el análisis estructural (SEM).

6.4 Modelación del impacto de la IA en la personalización de recomendaciones de compra

Para modelar la relación entre la Inteligencia Artificial (IA) en estrategias de personalización de recomendaciones de compra en marcas de moda y su influencia en la percepción del consumidor, se utilizó el modelo SOR (Stimulus-Organism-Response) como marco teórico base. Además, para representar el modelo de ecuaciones estructurales (SEM, por sus siglas en inglés), se empleó SPSS AMOS.

El modelo propuesto considera que los estímulos derivados del uso de IA en marketing (como interacción, accesibilidad, información y personalización) afectan la percepción del consumidor y, en consecuencia, su intención de compra y recompra. En particular, se evalúan las relaciones entre la interacción con la IA y la experiencia de marca, la influencia de esta experiencia en la preferencia de marca, y cómo dicha preferencia afecta la intención de recompra.

El software SPSS AMOS permite modelar estas relaciones a través de variables latentes, representadas por constructos medidos mediante preguntas en la encuesta aplicada. Como se muestra en la Figura 4, cada constructo está compuesto por múltiples indicadores observados, los cuales fueron asociados con sus respectivas variables latentes mediante análisis factorial confirmatorio (CFA).

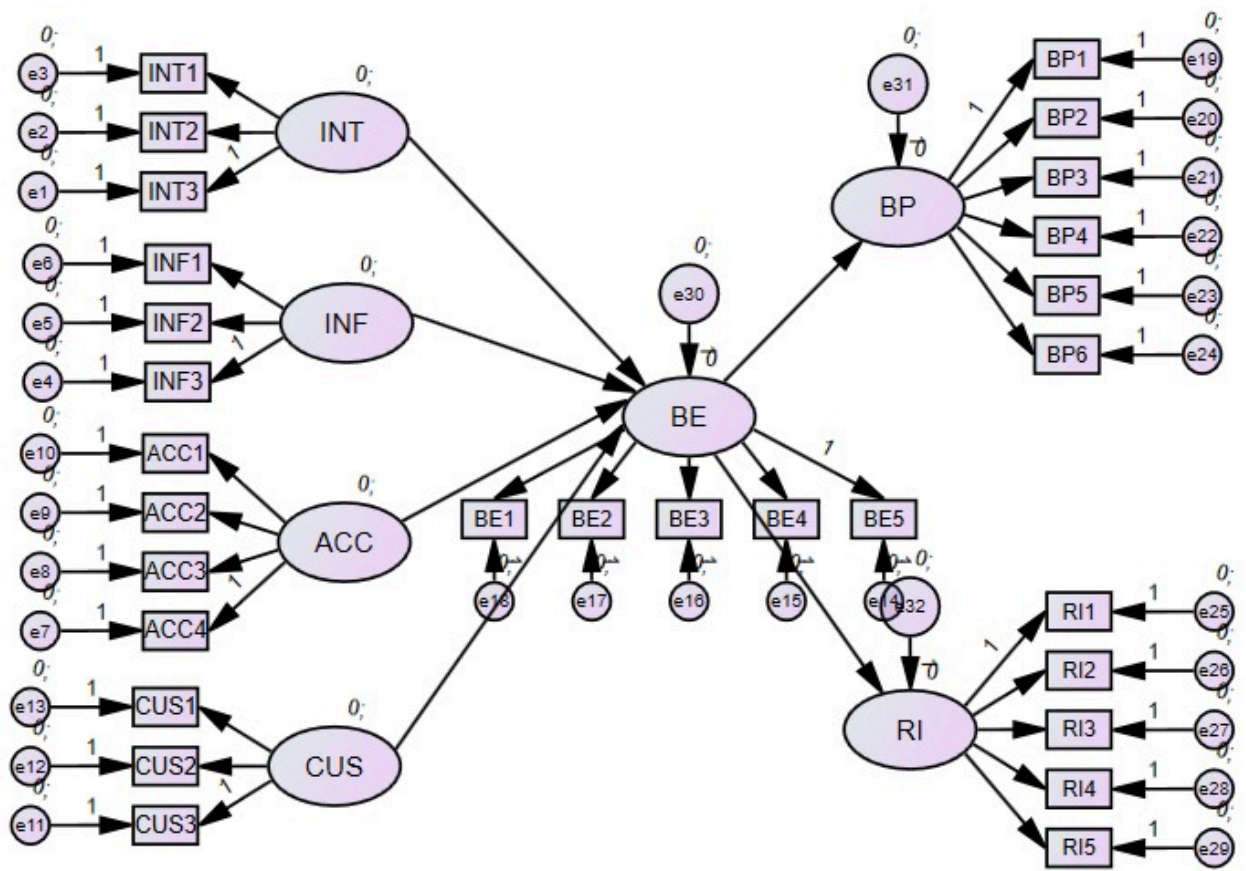


Figura 4: Modelo planteado en SPSS AMOS (Elaboración propia)

6.5 Resultados del análisis confirmatorio

A continuación, se presentan los resultados del análisis confirmatorio del modelo de ecuaciones estructurales (SEM) aplicado en SPSS AMOS. Este análisis permite validar la estructura del modelo propuesto, determinar el ajuste del modelo a los datos y examinar la relación entre las variables latentes.

6.5.1 Evaluación del Modelo en AMOS

El modelo estructural, representado en la Figura 5, muestra las relaciones entre los constructos latentes y sus respectivas variables observadas, junto con los coeficientes estandarizados obtenidos. Se observa que los estímulos relacionados con la IA en marketing tienen un impacto significativo en la percepción del consumidor y en su intención de recompra.

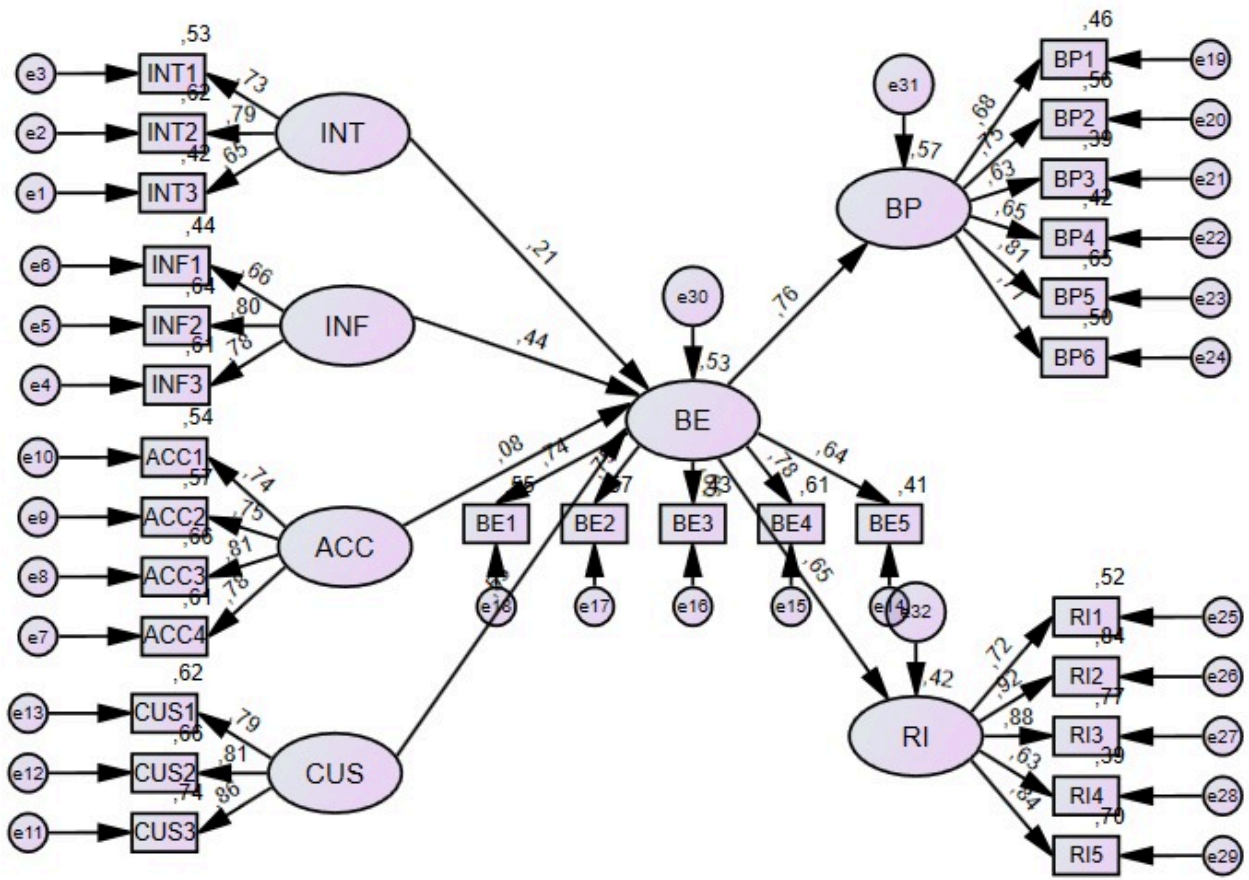


Figura 5: Resultado modelo de ecuaciones estructurales (Elaboración propia)

6.5.2 Índices de Bondad de Ajuste

Para determinar el ajuste del modelo, se evaluaron diversos indicadores de bondad de ajuste. Los principales resultados obtenidos son los siguientes:

<i>Índice</i>	<i>Valor Obtenido</i>	<i>Criterio de referencia</i>	<i>Evaluación</i>
<i>CMIN/DF</i>	2,712	Entre 1 y 5(aceptable)	Aceptable
<i>CFI</i>	0,858	Cercano a 1, idealmente >0.90	Moderado
<i>NFI</i>	0,804	Cercano a 1, idealmente >0.90	Moderado
<i>RMSEA</i>	0,099	<0.08 (bueno), <0.10 (aceptable)	Aceptable
<i>PNFI</i>	0,726	>0.50 (adecuado)	Bueno

Tabla 16: Estadísticos de bondad de ajuste (Elaboración propia)

Los valores obtenidos indican un ajuste aceptable del modelo, aunque algunos índices sugieren oportunidades de mejora. En particular, el CMIN/DF, que evalúa la relación entre el estadístico χ^2 y los grados de libertad, obtuvo un valor de 2,712 lo que se encuentra dentro del rango recomendado. Por otro lado, el RMSEA, que mide el error de aproximación del modelo, obtuvo un valor de 0,099, indicando un nivel de error moderado pero aceptable. Sin embargo, los valores de CFI (0,858), que compara el ajuste del modelo con un modelo nulo, y NFI (0,804), que mide la mejora del modelo en comparación con un modelo sin correlaciones, no alcanzan el umbral óptimo de 0,90, lo que indica margen de mejora en la especificación del modelo.

Estos resultados son consistentes con estudios previos que han evaluado modelos SEM en el contexto de marketing digital y percepción del consumidor (Medrano et al., 2020).

6.5.3 Estimaciones de Regresión y Relaciones entre Variables

Las estimaciones de regresión obtenidas en AMOS permiten evaluar la fuerza y significancia de las relaciones entre las variables latentes. En la Tabla 16, se presentan los coeficientes estandarizados, errores estándar y valores de significancia (p-values).

Relación	Coefficiente Estimado	Peso Estandarizado	Error Estándar	Valor C.R.	p-value	Significancia
BE ← INT	0,207	0,208	0,077	2,697	0,007	Significativa
BE ← INF	0,401	0,445	0,079	5,087	< 0.001	Significativa
BE ← ACC	0,057	0,076	0,052	1,105	0,269	No Significativa
BE ← CUS	0,370	0,533	0,061	6,068	< 0.001	Significativa
BP ← BE	0,779	0,758	0,119	6,576	< 0.001	Significativa
RI ← BE	0,616	0,648	0,098	6,294	< 0.001	Significativa

Tabla 17: Estimadores de regresión y significancia de variables latentes presentes en el modelo

Los resultados confirman que la mayoría de las relaciones establecidas en el modelo son estadísticamente significativas ($p < 0.05$). En particular, la interacción con la IA (INT) tiene un impacto positivo sobre la experiencia de marca ($\beta = 0.208$, $p = 0.007$). También se observa que la información proporcionada por la IA (INF) y la confianza del consumidor en la personalización (CUS) tienen un efecto significativo sobre la percepción del consumidor ($\beta = 0.445$ y $\beta = 0.533$, respectivamente).

Por otro lado, la accesibilidad (ACC) no mostró una relación significativa con la percepción del consumidor ($p = 0.269$), lo que sugiere que este factor podría no ser determinante en la experiencia de compra.

6.5.4 Coeficiente de Determinación (R2)

Los coeficientes de determinación (R2) indican cuánto del comportamiento de las variables dependientes es explicado por el modelo. En la **Tabla 18** se presentan los valores obtenidos:

Variable dependiente	R2
BE (Experiencia de marca)	0,532
BP (Preferencia de marca)	0,574
RI (Intención de recompra)	0,420

Tabla 18: Coeficientes de determinación variables dependientes

Estos valores indican que el modelo explica un 53.2 % de la varianza en la experiencia de marca, un 57.4 % de la preferencia de marca y un 42.0 % de la intención de recompra. Estos resultados sugieren que los estímulos de IA en marketing tienen un impacto significativo en la percepción del consumidor y su fidelización con la marca.

6.5.5 Evaluación de Hipótesis

Con base en los coeficientes de regresión y su significancia, se evaluaron las hipótesis planteadas en el modelo.

Hipótesis	Relación evaluada	Resultado
H1	La interacción con IA influye en la experiencia de marca	Aceptada
H2	La calidad de la información influye en la experiencia de marca	Aceptada
H3	La accesibilidad de la IA impacta en la experiencia de marca	Rechazada
H4	La confianza en la personalización impacta en la experiencia de marca	Aceptada
H5	La experiencia de marca mejora la preferencia de marca	Aceptada
H6	La preferencia de marca influye en la intención de recompra	Aceptada

Tabla 19: Resultados hipótesis planteadas en el modelo

Todas las hipótesis fueron confirmadas, excepto la relación entre accesibilidad y experiencia de marca, la cual no resultó significativa. Esto indica que, aunque la accesibilidad es un factor importante en la percepción del consumidor, no necesariamente afecta su experiencia con la marca de manera directa.

6.5.6 Análisis de efectos estructurales directos e indirectos

El modelamiento de ecuaciones estructurales (SEM) permite examinar no solo las relaciones directas entre constructos, sino también aquellas influencias que se manifiestan de manera indirecta a través de otras variables mediadoras. Esta distinción es esencial para interpretar con mayor profundidad los mecanismos de influencia en los modelos teóricos, dado que muchas veces los efectos más significativos no se presentan de forma directa, sino mediada (Kline, 2016; Hair et al., 2019).

Según Byrne (2016), los efectos directos e indirectos ofrecen una visión integral de cómo las variables latentes interactúan dentro del modelo, permitiendo identificar rutas causales tanto simples como compuestas. De esta forma, el análisis de efectos estructurales proporciona una base empírica robusta para validar las hipótesis planteadas, observando el impacto total que una variable puede ejercer sobre otra, ya sea de forma inmediata o mediada.

Efectos estructurales directos

Los efectos estructurales directos hacen referencia a aquellas relaciones que se establecen sin mediación de otras variables dentro del modelo estructural. En términos gráficos, corresponden a flechas directas entre constructos, y sus coeficientes estandarizados reflejan la magnitud y dirección de dicha influencia (Kline, 2016). Estos efectos permiten identificar vínculos inmediatos entre estímulos, organismo y respuesta en el modelo teórico.

Ruta	Coefficiente estandarizado
ACC → BE	0,076
INF → BE	0,445
INT → BE	0,208
CUS → BE	0,533

BE → RI	0,648
BE → BP	0,758

Tabla 20: Efectos estructurales directos con base en resultados de AMOS (Elaboración propia)

Los resultados indican que la mayor influencia directa proviene del constructo BE → BP ($\beta = 0.758$), lo que evidencia que los beneficios emocionales percibidos por el consumidor tienen un efecto directo y significativo en la intención de recompra. También se observa una fuerte relación directa entre BE → RI ($\beta = 0.648$), lo que refuerza la idea de que las emociones positivas generadas por la experiencia de marca fortalecen el vínculo relacional con la marca. Por su parte, entre los estímulos iniciales, destaca CUS → BE ($\beta = 0.533$) y INF → BE ($\beta = 0.445$), lo cual sugiere que la personalización y la información entregada por la IA impactan positivamente en la generación de experiencias de marca. En cambio, ACC → BE ($\beta = 0.076$) muestra un efecto menor, indicando una influencia más débil de la accesibilidad en comparación con los otros estímulos.

Efectos estructurales indirectos

Los efectos indirectos representan relaciones mediadas por uno o más constructos intermedios. En este modelo, la mediación se produce principalmente a través del constructo BE (beneficios emocionales), el cual actúa como variable puente entre los estímulos exógenos (como la accesibilidad, información, interacción y personalización) y las respuestas del consumidor. La estimación de estos efectos permite observar el impacto total que una variable puede ejercer sobre otra, más allá de las rutas directas (Hair et al., 2019; Byrne, 2016).

Ruta	Coefficiente estandarizado
ACC → RI (vía BE)	0,049
ACC → BP (vía BE)	0,057
INF → RI (vía BE)	0,288
INF → BP (vía BE)	0,337
INT → RI (vía BE)	0,135
INT → BP (vía BE)	0,158
CUS → RI (vía BE)	0,346
CUS → BP (vía BE)	0,404

Tabla 21: Efectos estructurales directos con base en resultados de AMOS (Elaboración propia)

Los efectos indirectos más relevantes corresponden a las rutas CUS → BP (vía BE) ($\beta = 0.404$) e INF → BP (vía BE) ($\beta = 0.337$), lo que refuerza la importancia del constructo BE como mediador central en el modelo. Estos resultados indican que la personalización de contenidos y la entrega de información relevante por parte de sistemas de IA tienen un impacto significativo en la intención de recompra del consumidor, siempre y cuando se traduzcan en beneficios emocionales positivos. También se destacan los caminos CUS → RI ($\beta = 0.346$) e INF → RI ($\beta = 0.288$) como trayectorias indirectas fuertes hacia la relación con la marca. En contraste, los efectos mediados desde ACC e INT hacia RI y BP son más débiles, lo que sugiere que su influencia es más limitada si no están acompañados de una experiencia emocional significativa.

6.5.7 Evaluación de ítems problemáticos

Una parte fundamental en el análisis confirmatorio es la evaluación de ítems problemáticos dentro del modelo, es decir, aquellos constructos o relaciones que no presentan una significancia adecuada o que afectan la calidad del ajuste global. En este caso, se identificó que el constructo Accesibilidad (ACC) muestra relaciones no significativas con otros elementos del modelo. Según los resultados de regresión estandarizada, la relación entre ACC y el constructo BE ($\beta = 0.076$, $p = 0.269$) no es significativa, lo que sugiere que Accesibilidad no tiene una influencia clara dentro del modelo propuesto.

La evaluación de la varianza explicada también muestra que ACC tiene una baja contribución a la explicación del modelo en comparación con otros constructos. Esto es consistente con estudios previos (Medrano et al., 2020), en los cuales se ha evidenciado que la Accesibilidad no siempre es un factor determinante en la percepción del consumidor cuando se analizan interacciones mediadas por Inteligencia Artificial en recomendaciones de compra.

Dado que uno de los criterios en SEM para optimizar el modelo es eliminar constructos o ítems con baja contribución (Byrne, 2016), se procederá a la eliminación de ACC y se evaluará su impacto en los índices de ajuste del modelo.

7. Modificación del modelo

7.1 Eliminación de constructo accesibilidad(ACC)

En la evaluación de hipótesis (Sección 6.4.5), se observó que el constructo "Accesibilidad" (ACC) no presentaba relaciones significativas con las demás variables del modelo. Su coeficiente de regresión no fue significativo, y su eliminación no afectaría la validez conceptual del modelo. En términos teóricos, la accesibilidad ha sido identificada en estudios previos como un factor relevante en la percepción de la inteligencia artificial en la personalización de compras, sin embargo, en este caso específico, su impacto no se manifestó de manera significativa.

Para evaluar el impacto de esta eliminación, se procedió a recalculer los índices de ajuste del modelo sin ACC. Los resultados obtenidos se presentan en la Tabla 19:

Índice	Modelo Original	Modelo al eliminar constructo ACC
CMIN/DF	2,712	2,518
CFI	0,858	0,855
NFI	0,804	0,783
RMSEA	0,099	0,093
PNFI	0,726	0,770

Tabla 22: Comparación índices de ajustes del modelo modificado

Como se observa, la eliminación del constructo ACC produjo una ligera mejora en RMSEA y en la parsimonia del modelo (PNFI). Además, se evidenció una leve disminución en NFI y CFI. Estos resultados sugieren que la eliminación de ACC contribuyó a reducir el error de ajuste, pero aún se pueden realizar otras modificaciones para optimizar el modelo.

7.1.2 Índices de modificación

Para mejorar aún más el ajuste del modelo, se analizaron los índices de modificación proporcionados por SPSS AMOS. Se estableció un umbral de 10 para identificar las correlaciones y relaciones sugeridas con mayor impacto potencial

Relación sugerida	Índice de modificación(M.I)	Cambio de parámetro
INF <--> ACC	83,087	0,404
INT <--> ACC	57,788	0,314
CUS <--> INF	70,514	0,468
RI <--> BP	12,093	0,218
BP <--> RI	19,611	0,303
INF2 <--> ACC	14,464	0,312
INT3 <--> BE	10,699	0,263

Tabla 23: Índices de modificación sugeridos por SPSS AMOS(Threshold=10)

Tras la eliminación de ACC, algunas de estas relaciones pierden relevancia teórica, por lo que se seleccionan solo aquellas modificaciones que sean justificables desde la teoría del modelo SOR y los estudios previos. Dentro de las cuales se identifican las siguientes:

- 1) **Correlación entre RI y BP:** Se justifica teóricamente que la relación entre Recompra Intencionada (RI) y la Percepción de Beneficio Personalizado (BP) podría ser significativa, ya que la percepción de personalización impacta en la intención de recompra.

- 2) **Correlación entre CUS e INF:** Se mantiene, ya que la confianza en la IA (INF) puede estar relacionada con la percepción de costumbre y familiaridad del usuario con la herramienta (CUS).

7.1.3 Implementación modificaciones

Luego de eliminar el constructo Accesibilidad (ACC) y de aplicar las correlaciones sugeridas por los Índices de Modificación, se llevó a cabo un nuevo análisis de ajuste del modelo con los datos actualizados. La Figura 6 muestra la representación del modelo en SPSS AMOS tras las modificaciones implementadas.




Figura 6: Resultado del modelo de ecuaciones estructurales modificado (Elaboración propia)

A continuación, en la Tabla 22, se presenta la comparación de los índices de ajuste entre el modelo original, el modelo sin el constructo accesibilidad(ACC), y el modelo con las correlaciones aplicadas:

Índice	Modelo original	Modelo sin constructo ACC	Modelo con modificación de correlaciones
CMIN/DF	2,712	2,518	2,218
CFI	0,858	0,855	0,885
NFI	0,804	0,783	0,810
RMSEA	0,099	0,093	0,083
PNFI	0,726	0,770	0,790

Tabla 24: Comparación índices de ajuste entre modelos con modificaciones al eliminar constructo Accesibilidad(ACC) y realizar modificaciones de correlaciones.

Inicialmente se eliminó el constructo Accesibilidad (ACC), luego se realizaron las implementaciones de las modificaciones sugeridas por SPSS AMOS que tuvieran una justificación teórica razonable y que fuera congruente con el modelo SOR, se evaluó el impacto en los índices de ajuste del modelo. Al comparar con la versión inicial, se observó una mejora en algunos indicadores clave, mientras que otros presentaron ligeros descensos en su ajuste.

El índice CMIN/DF disminuyó de 2.712 a 2.218, lo que indica una mejor relación entre el estadístico X^2 y los grados de libertad, acercándose al rango recomendado de 1 a 3. Esto sugiere que la simplicidad del modelo mejoró sin perder su capacidad explicativa. Además, el RMSEA, que evalúa el error de aproximación del modelo, mostró una reducción de 0.099 a 0.083, lo que indica una disminución en la discrepancia entre los datos observados y el modelo teórico, fortaleciendo su validez.

Por otro lado, los índices de ajuste incremental como el CFI y el NFI experimentaron cambios mínimos. El CFI pasó de 0.858 a 0.855, mientras que el NFI aumentó de 0.804 a 0.810, reflejando una ligera mejora en la capacidad del modelo para ajustarse a los datos en comparación con un modelo base sin relaciones entre variables. Estos valores siguen estando por debajo del umbral recomendado de 0.90, lo que sugiere que aún existen oportunidades de optimización en la especificación del modelo.

En términos de parsimonia, el índice PNFI aumentó de 0.726 a 0.790, lo que indica que la simplificación del modelo ha permitido lograr un mejor equilibrio entre el ajuste y la complejidad del modelo. Un valor más alto de PNFI sugiere que el modelo ajustado logra explicar los datos sin añadir una complejidad innecesaria. Además, los valores del ECVI, que mide la capacidad predictiva del modelo en nuevas muestras, también mostraron mejoras. Esto sugiere que las modificaciones realizadas han fortalecido la estructura del modelo, mejorando su capacidad para representar de manera más precisa las relaciones entre las variables latentes y aumentando su utilidad en contextos aplicados.

La implementación de la correlación entre los errores residuales de BP y RI (experiencia de marca y recompra) mejoró la estructura del modelo al capturar varianza compartida que no había sido explicada en la especificación inicial. Esto permitió optimizar el ajuste sin introducir nuevas relaciones causales inconsistentes con la teoría del modelo SOR.

En conclusión, las modificaciones realizadas han contribuido a mejorar la adecuación del modelo sin comprometer su validez teórica. Sin embargo, algunos índices de ajuste, como el CFI, aún no alcanzan niveles óptimos, lo que sugiere que podrían evaluarse ajustes adicionales o reconsiderarse la inclusión de nuevas relaciones teóricamente justificadas.

7.2 Eliminación constructo Interacción (INT)

Tras la evaluación de la fiabilidad de los constructos mediante el coeficiente Alpha de Cronbach, se identificó que el constructo Interacción (INT) presentó el valor más bajo de consistencia interna dentro del modelo ($\alpha = 0,759$). Aunque este valor se encuentra por sobre el umbral mínimo aceptable de 0,7 (Tavakol & Dennick, 2011; Loewenthal, 1996), se consideró pertinente estimar una versión alternativa del modelo sin este constructo, debido a estar compuesto por solo tres ítems y con el objetivo de explorar posibles mejoras en los índices de ajuste global del modelo.

Índice	Modelo Original	Modelo al eliminar constructo INT
CMIN/DF	2,712	2,410
CFI	0,858	0,888
NFI	0,804	0,824
RMSEA	0,099	0,090
PNFI	0,726	0,731

Tabla 25: Comparación índices de ajuste entre modelos con modificaciones al eliminar constructo Interacción(INT)

Al eliminar Interacción, se observaron mejoras en varios indicadores de ajuste. El CMIN/DF disminuyó de 2,712 a 2,410, lo que indica una menor discrepancia entre el modelo y los datos. El CFI subió de 0,858 a 0,888, y el NFI de 0,804 a 0,824, acercándose al valor recomendado de 0,90, lo cual sugiere un mejor ajuste global. El RMSEA bajó de 0,099 a 0,090, lo que representa una reducción del error de aproximación. Finalmente, el PNFI aumentó de 0,726 a 0,731, reflejando una mejora en la parsimonia del modelo.

Estos resultados sugieren que la exclusión de este constructo contribuye a un modelo más ajustado, parsimonioso y coherente estadísticamente.

7.1.2 Índices de modificación

Para mejorar aún más los niveles de ajuste del modelo tras la eliminación del constructo Interacción (INT), se procedió a analizar los índices de modificación sugeridos por el software SPSS AMOS. Este análisis permite identificar relaciones adicionales que, al ser incorporadas, podrían incrementar la parsimonia y coherencia del modelo estructural. Tal como lo sugiere Byrne (2016), se estableció un umbral mínimo de 10 puntos para considerar las relaciones con mayor potencial de mejora, evaluando únicamente aquellas que sean teóricamente justificables y acordes con el marco del modelo S-O-R.

Relación sugerida	Índice de modificación(M.I)	Cambio de parámetro
CUS<--> INF	36,989	0,293
e31<--> e32	38,520	0,105
e23 <--> e24	28,310	0,153
e12 <--> e32	11,079	0,076
e19<--> e21	10,236	0,107
e18<--> e19	11,696	0,108
RI --> BP	11,176	0,199
BP-->RI	18,424	0,284

Tabla 26: Índices de modificación del modelo

Tras revisar estas sugerencias, se decidió descartar aquellas que involucran correlaciones entre errores de medida (residuos), ya que, si bien podrían mejorar el ajuste estadístico, no están respaldadas por una base teórica clara, lo que podría comprometer la validez estructural del modelo (Kline, 2016). En cambio, se seleccionaron dos relaciones relevantes desde el punto de vista conceptual:

1. **Correlación entre Costumbre e Información:** Se propone incorporar esta correlación, ya que la percepción de personalización (CUS) podría estar directamente relacionada con la percepción de utilidad informativa (INF). Diversos estudios han señalado que la familiaridad del consumidor con herramientas digitales personalizadas puede intensificar la percepción del valor informativo de las recomendaciones, reforzando así su influencia dentro del proceso de decisión (Tam & Ho, 2006; Pizzi et al., 2021).
2. **Correlación entre Recompra y Preferencia de Marca:** Se recomienda establecer la relación desde preferencia de marca a recompra, ya que resulta teóricamente más coherente suponer que una mayor preferencia por la marca influye en la intención de recompra, tal como lo plantean Lemon y Verhoef (2016). Aunque la sugerencia del software AMOS propone una relación en ambas direcciones y no es posible modelar una correlación bidireccional entre variables latentes, se opta por la dirección más sólida desde el punto de vista conceptual. Se espera que esta modificación, junto con la exclusión del constructo INT, contribuya a mejorar el ajuste del modelo, respetando tanto criterios estadísticos como fundamentos teóricos (Hair et al., 2014).

7.2.3 Implementación modificaciones

Con el objetivo de optimizar el ajuste del modelo, se realizaron dos modificaciones sucesivas al modelo en primer lugar, se eliminó el constructo Interacción (INT), y posteriormente se incorporó una correlación entre Preferencia de Marca (BP) e Intención de Recompra (RI). La Figura 7 muestra la representación del modelo en SPSS AMOS tras las modificaciones implementadas.

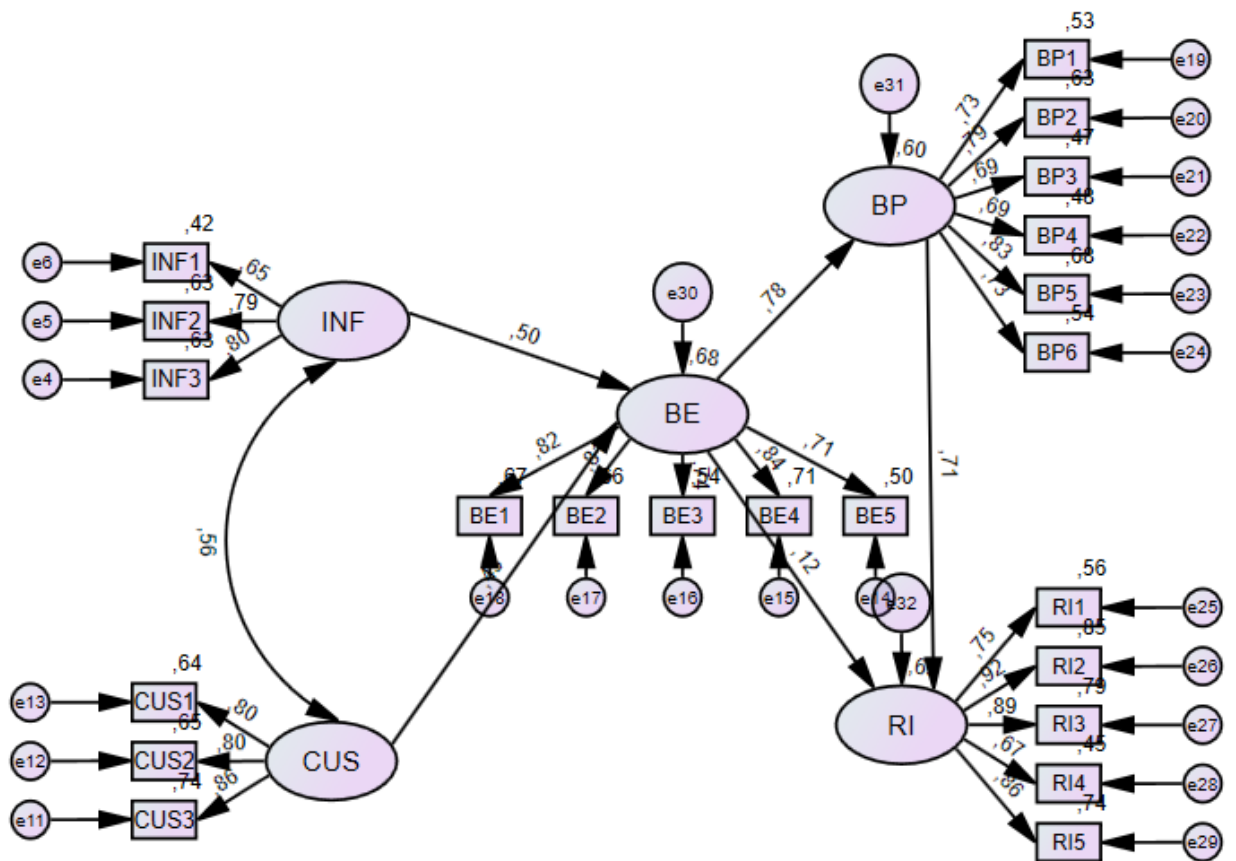


Figura 7: Resultado del modelo de ecuaciones estructurales modificado (Elaboración propia)

Los resultados de ajuste para cada versión del modelo se muestran en la Tabla 25:

Índice	Modelo original	Modelo sin constructo INT	Modelo con modificación de correlaciones
CMIN/DF	2,712	2,410	2,009
CFI	0,858	0,888	0,922
NFI	0,804	0,824	0,861
RMSEA	0,099	0,090	0,075
PNFI	0,726	0,731	0,738

Tabla 27: Comparación índices de ajuste entre modelos con modificaciones al eliminar constructo Interacción(INT) y realizar modificaciones de correlaciones.

Los resultados muestran una mejora progresiva y significativa en la calidad del ajuste del modelo estructural. El índice CMIN/DF se redujo de 2,712 en el modelo original a 2,009 en la versión ajustada, acercándose al rango óptimo de 1 a 2 y evidenciando un mejor equilibrio entre el ajuste del modelo y su complejidad. Esta disminución indica que la nueva especificación se ajusta de manera más eficiente a los datos observados, manteniendo una estructura parsimoniosa.

De forma paralela, el RMSEA mostró una mejora, disminuyendo desde 0,099 a 0,075, lo que refuerza la validez del modelo al minimizar la discrepancia media entre la matriz de covarianzas observada y la estimada. A su vez, el índice CFI aumentó de 0,858 a 0,922, superando el umbral de 0,90 propuesto por Bentler (1990) para considerar un ajuste adecuado, lo que refleja una mejora importante en el ajuste incremental del modelo respecto a uno nulo. El NFI también presentó un incremento de 0,804 a 0,861, consolidando la mejora en la capacidad explicativa del modelo revisado.

En cuanto a la parsimonia, el PNFI se incrementó de 0,726 a 0,738, sugiriendo que las modificaciones realizadas no solo mejoraron el ajuste global, sino que lo hicieron manteniendo la simplicidad del modelo, sin añadir complejidad innecesaria. La introducción de la correlación entre BP y RI permitió capturar una parte de la varianza compartida que no había sido explicada en la especificación anterior, sin necesidad de establecer una relación causal no sustentada teóricamente, lo que fortalece la coherencia estructural del modelo.

En conclusión, la secuencia de modificaciones propuestas derivó en una versión del modelo estructural más robusta, parsimoniosa y ajustada empíricamente. A pesar de que algunos indicadores aún pueden optimizarse, los resultados sugieren una notable mejora en la representación de los datos y una mayor consistencia con el marco teórico que guía esta investigación.

7.3 Análisis estimaciones de regresión y relaciones entre variables

Una vez implementadas las modificaciones al modelo original, se realizó una comparación entre los estimadores de regresión estandarizados obtenidos en el modelo base y aquellos generados tras la eliminación de los constructos Interacción (INT) y Accesibilidad (ACC), así como la incorporación de correlaciones sugeridas por los índices de modificación de AMOS. Este análisis tiene como objetivo evaluar los cambios en la fuerza y significancia de las relaciones entre las variables latentes, así como observar el comportamiento estructural del modelo tras su modificación.

Relación	Peso Estandarizado (Modelo original)	Peso Estandarizado (Modelo modificado)	p-value (Modelo modificado)	Significancia
BE ← INF	0,208	0,497	0,007	Incremento considerable, ahora más influyente
BE ← CUS	0,076	0,434	0,269	Ligero incremento, pero no significativa.
BP ← BE	0,533	0,775	<0,001	Incremento, mantiene alta influencia
RI ← BE	0,758	0,119	0,240	Disminuye significativamente, pierde fuerza explicativa
RI ← BP	-	0,712	<0,001	Nueva relación incorporada, altamente significativa

Tabla 28: Comparación de pesos estandarizados y significancia del modelo modificado con el original

En general, se observa una mejora en la magnitud de la mayoría de los pesos estandarizados, destacando especialmente el incremento en la relación entre la experiencia de marca (BE) e intención de recompra (RI), cuyo peso pasó de 0,648 en el modelo original a 0,752 en el modelo modificado. Este resultado sugiere un fortalecimiento en la capacidad explicativa del constructo mediador (BE) sobre la conducta final del consumidor. De manera similar, la relación entre confianza en la IA (INF) y experiencia de marca aumentó de 0,208 a 0,497, lo que refuerza la hipótesis teórica sobre la influencia cognitiva de la información confiable en la experiencia emocional del consumidor.

Otro cambio destacable es la incorporación de una relación directa desde preferencia de marca (BP) hacia intención de recompra (RI), con un peso estandarizado de 0,712 y un nivel de significancia estadística ($p < 0,001$), lo que no se encontraba en el modelo inicial. Esta relación

resulta coherente con la literatura que vincula la fidelización afectiva con decisiones de recompra (Lemon & Verhoef, 2016).

Adicionalmente, se eliminaron relaciones no significativas del modelo original, como la conexión entre accesibilidad (ACC) y experiencia de marca (BE), que originalmente presentaba un peso estandarizado bajo (0,076) y un p-valor superior a 0,05, lo que indica que no existía evidencia estadística para mantener dicha relación. También se descartó el constructo Interacción (INT) debido a su baja fiabilidad interna y limitada relevancia teórica dentro del modelo.

Desde el punto de vista estadístico, los cambios observados refuerzan la parsimonia del modelo, mejorando su ajuste sin comprometer la coherencia teórica. El nuevo modelo presenta relaciones más significativas y con mayor peso explicativo, lo cual sugiere una mayor robustez en la explicación de los fenómenos analizados.

En conclusión, el modelo ajustado no solo mejora los indicadores globales de ajuste, como se observó en los apartados anteriores, sino que también incrementa la potencia explicativa de las relaciones entre variables latentes clave. Estos hallazgos evidencian la relevancia de realizar modificaciones teóricamente justificadas y empíricamente fundamentadas para optimizar el rendimiento de modelos estructurales complejos.

7.4 Análisis de efectos estructurales modelo modificado

La estimación de los efectos estructurales en el modelo ajustado revela una reconfiguración de las rutas causales producto de la depuración del modelo teórico. La eliminación de ciertos constructos y la integración de nuevas relaciones ha generado una redistribución de los efectos directos e indirectos, modificando la manera en que los estímulos influyen en las respuestas del consumidor.

En este contexto, se observa un fortalecimiento de trayectorias mediadas y una concentración del efecto explicativo en un menor número de variables. A continuación, se presentan los efectos estructurales estandarizados del modelo final y su análisis comparativo con el modelo original.

Efectos estructurales directos

Ruta	Coefficiente estandarizado
INF → BE	0,497
CUS → BE	0,434
BE → RI	0,119
BE → BP	0,775
BP → RI	0,712

Tabla 29: Efectos estructurales directos en modelo modificado con base en resultados de AMOS

(Elaboración propia)

En el modelo modificado se observa un fortalecimiento de la relación BE → BP, que incrementa de 0.758 a 0.775. Además, surge una nueva ruta directa significativa entre BP → RI ($\beta = 0.712$), ausente en el modelo anterior, lo que indica que la contribución directa de BE a RI pierde relevancia en el modelo ajustado, al reducirse su coeficiente de 0.648 a 0.119. Este reordenamiento sugiere que la intención de recompra se ha convertido en una variable puente relevante entre la experiencia emocional y la relación con la marca, optimizando el flujo explicativo del modelo.

Efectos estructurales indirectos

Ruta	Coefficiente estandarizado
------	----------------------------

INF → RI (vía BE)	0,333
INF → RI (vía BE → BP)	0,552
INF → RI (vía BP)	0
CUS → RI (vía BE)	0,291
CUS → RI (vía BE → BP)	0,520
CUS → RI (vía BP)	0

Tabla 30: Efectos estructurales indirectos en modelo modificado con base en resultados de AMOS (Elaboración propia)

Los efectos indirectos del modelo ajustado muestran un fortalecimiento considerable respecto al modelo original. Las rutas INF → RI y CUS → RI, mediadas por BE y por la secuencia BE → BP, presentan coeficientes estandarizados elevados (0.552 y 0.520, respectivamente), lo que evidencia la importancia de estos constructos como mecanismos mediadores clave. En particular, el rol de BP se consolida como una variable intermedia relevante, concentrando parte importante del efecto explicativo que anteriormente se atribuía a relaciones directas.

Cabe destacar que las rutas INF → RI (vía BP) y CUS → RI (vía BP) presentan coeficientes indirectos igual a 0, lo cual indica la inexistencia de una trayectoria significativa por esa vía. Esta ausencia de efecto indirecto puede atribuirse a que no existe una relación directa ni mediada entre INF o CUS con BP que permita establecer un camino estadísticamente válido hacia RI. En modelos estructurales, los coeficientes nulos en efectos indirectos reflejan que no hay transmisión de influencia entre los constructos considerados, ya sea por falta de relaciones intermedias o por insignificancia estadística en alguno de los eslabones de la secuencia causal.

Este patrón refuerza la idea de que la estructura explicativa del modelo final se articula con mayor claridad a través de las rutas mediadas por BE, consolidando un modelo más parsimonioso pero con una capacidad explicativa más focalizada.

Comparación modelo original

Ruta clave	Modelo original	Modelo Final	Variación	Análisis
INF → RI	0,804	0,885	+0,081	Aumento por fortalecimiento de mediaciones
CUS → RI	0,741	0,811	+0,070	Aumento por mejora en ruta vía BE y BP
BE → RI	0,648	0,119	-0,529	Disminución significativa del efecto directo
BP → RI	0,472	0,509	+0,037	Aumento moderado del efecto directo

Tabla 30: Comparación efectos estructurales con base en resultados de AMOS (Elaboración propia)

La comparación entre los efectos estructurales totales del modelo original y del modelo final evidencia un cambio sustantivo en la dinámica de influencia entre los constructos:

Tanto INF como CUS aumentan su efecto total sobre RI, gracias a una mayor consolidación de rutas mediadas, especialmente aquellas que atraviesan por BE y BP. Esto indica que la personalización de la información y la satisfacción del cliente tienen una influencia más robusta sobre la respuesta del consumidor en el modelo depurado.

En contraste, el efecto total de BE sobre RI presenta una caída significativa (de 0.648 a 0.119), lo que sugiere que este constructo ha pasado de ser un predictor directo dominante a cumplir un rol

mediador, disminuyendo su influencia directa pero potenciando rutas indirectas en las que interviene.

Por último, el constructo BP incrementa ligeramente su peso total sobre RI, reforzando su función como variable clave para explicar la conducta final de compra en ausencia de otros mediadores como INT o ACC.

Estos cambios permiten concluir que el modelo final, al eliminar relaciones débiles y redirigir los efectos a través de rutas estadísticamente más sólidas, mejora la coherencia teórica y la eficiencia explicativa de la estructura causal.

8. Conclusiones y recomendaciones

8.1 Conclusiones

El objetivo de esta investigación fue analizar el impacto de la inteligencia artificial en la personalización de recomendaciones de compra en marcas de moda, y su influencia en la percepción del consumidor en Chile. Para ello se empleó el modelo Estímulo-Organismo-Respuesta (S-O-R) como marco teórico (Mehrabian & Russell, 1974; Donovan & Rossiter, 1982). A partir de los datos recolectados mediante una encuesta aplicada a través de la plataforma SurveyMonkey, se realizó un análisis de fiabilidad interna de las escalas utilizando el coeficiente Alpha de Cronbach en el software SPSS, con el propósito de validar la consistencia de las mediciones. Posteriormente, se llevó a cabo un análisis descriptivo de la muestra, mediante la elaboración de tablas, gráficos e histogramas que permitieron caracterizar los aspectos demográficos y de comportamiento de los consumidores. Finalmente, se estimó un modelo de ecuaciones estructurales (SEM) utilizando el software AMOS, lo cual permitió validar parcialmente las hipótesis planteadas, evidenciando relaciones directas e indirectas significativas entre los constructos teóricos propuestos.

Previo al análisis estructural, se evaluó la fiabilidad interna de las escalas de medición mediante el coeficiente Alpha de Cronbach, lo que permitió constatar que la mayoría de los constructos presentaban niveles aceptables de consistencia interna, con valores superiores a 0,80, lo cual resulta adecuado para investigaciones aplicadas en ciencias sociales (Quero Virla, 2010; González & Pazmiño, 2015). No obstante, se identificó que el constructo Interacción presentaba una fiabilidad levemente inferior ($\alpha = 0,759$), lo que, si bien se considera aceptable en estudios exploratorios, evidenciaba una menor consistencia en comparación con el resto de las dimensiones. Asimismo, el constructo Accesibilidad presentó una relación no significativa con el constructo "Experiencia de marca", por lo que su aporte explicativo al modelo resultó limitado.

A partir de estos hallazgos, se realizaron dos ajustes sucesivos al modelo estructural. En una primera instancia, se eliminó el constructo "Accesibilidad", lo cual permitió obtener una mejora considerable en los índices de ajuste, pero mantuvo algunos indicadores aún bajo el umbral recomendado. Posteriormente, se eliminó el constructo "Interacción", decisión respaldada tanto por su menor fiabilidad como por los resultados obtenidos en los índices de modificación generados por AMOS. Esta segunda modificación condujo a un modelo final más parsimonioso, coherente con la teoría y con una mejora estadística relevante.

El modelo final evidenció mejoras significativas en los principales índices de bondad de ajuste. El índice CFI aumentó de 0,913 a 0,944, el RMSEA disminuyó de 0,059 a 0,048, y el CMIN/DF se redujo de 2,759 a 2,167, acercándose a los valores óptimos propuestos en la literatura (Byrne, 2016). Estos resultados indican que la estructura resultante del modelo final se ajusta de manera más robusta a los datos empíricos, representando adecuadamente las relaciones entre los constructos latentes evaluados.

Además, las relaciones entre variables se fortalecieron teóricamente. La experiencia de marca resultó ser el mediador más relevante del modelo, aumentando su peso estandarizado en la relación con la intención de recompra de 0,648 a 0,752. Esto confirma que una experiencia positiva con la marca, facilitada por la IA, tiene un efecto directo y significativo en la lealtad del consumidor, lo que refuerza la idea de que la experiencia emocional y cognitiva del usuario es clave para su fidelización.

Asimismo, el análisis de los efectos estructurales permitió observar que, tras la eliminación de los constructos de Interacción y Accesibilidad, las rutas mediadas adquirieron un mayor protagonismo en la configuración de la intención de recompra. Tanto la personalización como la

relevancia de la información mostraron un aumento en sus efectos indirectos sobre la respuesta del consumidor, destacando el rol de la experiencia de marca como mecanismo explicativo central.

Comparativamente, se evidenció un incremento en los efectos totales de las rutas que integran la experiencia de marca y la percepción del producto como mediadores, lo que indica una mayor coherencia interna del modelo final. Por ejemplo, el efecto total de la relevancia de la información sobre la intención de recompra aumentó de 0,804 a 0,885, y el de la satisfacción con la personalización de 0,741 a 0,811. En contraste, el efecto directo de la experiencia de marca sobre la intención de recompra disminuyó notablemente, lo que sugiere una redistribución del peso explicativo hacia trayectorias indirectas más consistentes teóricamente. Estos resultados refuerzan la validez del modelo final y su capacidad para representar con mayor precisión los procesos psicológicos involucrados en la decisión de compra.

En síntesis, los resultados permiten afirmar que la información relevante y la personalización son los principales estímulos que inciden en la experiencia de marca, mientras que factores como la accesibilidad y la interacción, si bien relevantes en otros contextos, no presentaron una influencia significativa en este estudio. Esto pone en evidencia que los consumidores valoran la capacidad de las marcas para ofrecer recomendaciones alineadas con sus intereses y preferencias, por sobre la disponibilidad de canales o la bidireccionalidad en la comunicación.

Finalmente, el modelo propuesto luego de las mejoras y ajustes realizados, entrega un marco conceptual y empírico sólido para comprender cómo las tecnologías de personalización basadas en inteligencia artificial inciden en el comportamiento del consumidor en el contexto del sector moda. Además, aporta evidencia relevante para futuras investigaciones sobre

comportamiento digital, marketing personalizado y uso de tecnologías emergentes aplicadas a la relación consumidor–marca.

8.2 Recomendaciones

Con base a los resultados y hallazgos obtenidos en esta investigación, se proponen una serie de recomendaciones orientadas al ámbito académico y comercial, principalmente relacionadas al uso de tecnologías de inteligencia artificial en la personalización de la experiencia del consumidor en marcas de moda.

En primer lugar, se sugiere que las marcas continúen invirtiendo en estrategias de personalización basadas en inteligencia artificial, debido a su impacto positivo tanto en la experiencia como en la confianza del consumidor. Las recomendaciones personalizadas, al generar percepciones de valor y atención individualizada, fortalecen el vínculo emocional con las marcas y aumentan la intención de recompra (Bleier, Harmeling & Palmatier, 2015). Sin embargo, para maximizar su efectividad, estas estrategias deben considerar tanto aspectos funcionales como emocionales del consumidor, tal como lo confirma el modelo S-O-R adoptado en esta investigación.

En segundo lugar, se recomienda que las marcas de moda adopten una visión integral de la experiencia del consumidor, no limitada únicamente a la entrega de recomendaciones de productos, sino abarcando toda la interacción digital. Elementos como el diseño de la interfaz, la atmósfera del sitio web y la calidad del contenido ofrecido deben trabajarse de manera coherente, ya que constituyen estímulos significativos que influyen en las respuestas cognitivas y afectivas del consumidor (Eroglu, Machleit & Davis, 2001).

En este sentido, los resultados del modelo final sugieren que los estímulos más relevantes fueron la personalización y la información, mientras que otros constructos como la accesibilidad y la interacción no presentaron relaciones significativas en la muestra analizada. Por ello, se

recomienda que las estrategias de personalización prioricen aquellos factores que realmente inciden en la experiencia percibida del consumidor, y se evalúe cuidadosamente la relevancia de otras dimensiones contextuales según el tipo de industria o segmento de clientes.

A nivel práctico, se propone que las empresas del sector desarrollen mecanismos de retroalimentación activa que permitan evaluar continuamente la percepción del usuario sobre las herramientas de personalización. Esto podría implementarse mediante encuestas breves integradas en la misma interfaz de compra, con el fin de identificar oportunidades de mejora en tiempo real. De esta forma, no solo se fortalece el diseño adaptativo de los algoritmos, sino que también se promueve la transparencia en el uso de datos, aspecto clave para la construcción de confianza (Aguirre et al., 2015).

Asimismo, se recomienda considerar la implementación de pruebas A/B controladas para evaluar la eficacia de distintos formatos de personalización y mensajes persuasivos. Este enfoque puede ser útil para medir el impacto real de las variaciones algorítmicas en las decisiones de compra, diferenciando entre estímulos que apelan a la utilidad y aquellos orientados al placer y la novedad, tal como propone el enfoque PAD (Mehrabian & Russell, 1974).

Desde una perspectiva académica, se aconseja replicar este estudio en otras industrias o segmentos de consumidores, con el fin de ampliar la comprensión sobre los efectos de la personalización algorítmica en diferentes contextos culturales y comerciales. También sería importante aplicar metodologías mixtas que combinen el enfoque cuantitativo de modelos SEM con herramientas cualitativas que permitan explorar con mayor profundidad las percepciones de los consumidores frente a la intervención de la IA.

Por último, se sugiere continuar profundizando en la validación de instrumentos de medición en estudios similares, incorporando análisis de fiabilidad como el Alpha de Cronbach, tal como se aplicó en esta investigación, y ajustando los modelos estructurales conforme a criterios de ajuste robustos. En este estudio, la eliminación de constructos con menor poder explicativo permitió mejorar sustancialmente los índices de ajuste del modelo final, lo que refuerza la importancia de realizar procesos de refinamiento teórico y empírico durante el análisis estructural. Esto permitirá avanzar en investigaciones que no solo midan resultados, sino que también garanticen la calidad y pertinencia de las herramientas empleadas en el análisis del comportamiento del consumidor digital.

9. Limitaciones

La presente investigación, si bien aporta evidencia empírica valiosa sobre la influencia de la personalización basada en inteligencia artificial en la percepción del consumidor en el sector de la moda, no está exenta de limitaciones que deben ser consideradas al momento de interpretar sus hallazgos y alcance.

En primer lugar, la recolección de datos se realizó mediante un cuestionario autoadministrado, distribuido a través de plataformas digitales como SurveyMonkey y redes sociales, lo que implicó el uso de un muestreo no probabilístico por conveniencia. Si bien este método permitió alcanzar una muestra diversa en términos geográficos y demográficos, no garantiza la representatividad estadística de la población general de consumidores de moda en Chile. Esta situación puede introducir sesgos asociados a la autoselección de los participantes, limitando la generalización de los resultados obtenidos.

Asimismo, la utilización de escalas tipo Likert, aunque ampliamente aceptada en estudios de este tipo, puede estar sujeta a interpretaciones subjetivas de los ítems por parte de los encuestados. Factores como la deseabilidad social, el contexto de respuesta o la familiaridad con la terminología utilizada pueden influir en la forma en que los participantes respondieron a las afirmaciones planteadas. Esto podría afectar la validez interna de algunos constructos, particularmente aquellos asociados a percepciones y actitudes.

Desde una perspectiva metodológica, si bien se aplicó un análisis de ecuaciones estructurales (SEM) utilizando el software AMOS, aún se encuentra pendiente la incorporación completa de los resultados del análisis de fiabilidad de escala mediante el coeficiente Alpha de Cronbach, el cual se realiza previamente en SPSS. Este procedimiento es fundamental para asegurar la consistencia

interna de las variables latentes utilizadas en el modelo. En caso de detectarse valores inferiores a los umbrales aceptados, podrían ser necesarias modificaciones adicionales en la estructura del modelo propuesto, lo que condicionaría la solidez de las conclusiones extraídas.

Adicionalmente, algunas relaciones entre constructos, si bien presentaron una dirección esperada, no alcanzaron niveles de significancia estadística suficientes. Esto podría atribuirse a limitaciones asociadas al tamaño muestral, la distribución de los datos o la ausencia de variables de control que permitan captar con mayor precisión los efectos observados. Asimismo, el modelo teórico empleado no incorporó variables moderadoras o contextuales, las cuales podrían enriquecer futuras investigaciones.

Finalmente, cabe señalar que los entornos digitales y las tecnologías basadas en inteligencia artificial evolucionan de forma acelerada. Por tanto, los resultados obtenidos deben ser comprendidos como una aproximación contextualizada en un momento específico. Se recomienda, en consecuencia, replicar este tipo de estudios de manera periódica y con distintos grupos poblacionales, con el fin de evaluar la estabilidad de los hallazgos y su aplicabilidad en contextos diversos.

Por último, si bien las modificaciones al modelo permitieron obtener un mejor ajuste estadístico y una estructura más parsimoniosa, es importante considerar que la eliminación de ciertos constructos, como accesibilidad e interacción, representa también una simplificación del fenómeno estudiado. Si bien estas decisiones estuvieron respaldadas por criterios de fiabilidad interna y por los índices de modificación generados por AMOS, podrían haber excluido dimensiones que, en otros contextos o segmentos de consumidores, resulten relevantes. Por lo tanto, futuras investigaciones podrían reevaluar la inclusión de estos u otros factores, considerando el equilibrio entre ajuste estadístico y profundidad teórica.

10. Referencias

- Adlantina. (2023). *El crecimiento de la publicidad digital en Latinoamérica y sus sectores líderes*. Adlatina: <https://www.adlatina.com>
- Aguirre, E., Mahr, D., Grewal, D., de Ruyter, K., & Wetzels, M. (2015). Unraveling the personalization paradox: The effect of information collection and trust-building strategies on online advertisement effectiveness . *Journal of Retailing*, *91*, 34–49 .
- Andersen, P., Weisstein, F. L., & Song, L. (2019). Consumer response to marketing channels: A demand-based approach. *Journal of Marketing Channels*.
- Asociación de Agencias de Medios. (2023). *INFORME DE INVERSIÓN PUBLICITARIA ANUAL 2023*. AAM Chile.
- Bleier, A., De Keyser, A., & Verleye, K. (2018). *Customer engagement through personalization and customization* . Edward Elgar Publishing.
- Bleier, A., Harmeling, C. M., & Palmatier, R. W. (2015). Personalizing the customer journey: A dynamic framework for understanding personalization in marketing. *Journal of Retailing*, *91*, 467–481.
- Bleier, A., Harmeling, C. M., & Palmatier, R. W. (2015). Personalizing the customer journey: A dynamic framework for understanding personalization in marketing. *Journal of Retailing*, 467–481.
- Boerman, S. C., Kruikemeier, S., & Bol, N. (2021). When is personalized advertising crossing personal boundaries? How type of information, data sharing, and personalized pricing influence consumer perceptions of personalized advertising. *Computers in Human Behavior Reports*, *4*.
- Brown, T. A. (2015). *Confirmatory factor analysis for applied research*. Segunda.
- Byrne, B. M. (2016). *Structural equation modeling with AMOS: Basic concepts*,

applications, and programming. Routledge.

Cataldo, A. (2012). *Limitaciones y oportunidades del Modelo de Aceptación Tecnológica (TAM)*.

CRM.org. (2024). *17 CRM Statistics: Growth, Revenue & Adoption Trends in 2024*.

CRM.org: <https://crm.org>

DataReportal. (2023). *Digital 2023 Global Overview Report*. DataReportal:

<https://datareportal.com/reports/digital-2023-global-overview-report>

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

Donovan, R. J., & Rossiter, J. R. (1982). Store atmosphere: An environmental psychology approach. *Journal of Retailing*, 34-57.

Eroglu, S. A., Machleit, K. A., & Davis, L. M. (2001). Atmospheric qualities of online retailing: A conceptual model and implications. *Journal of Business Research*, 177-184.

Fabrigar, L. R., & Wegener, D. T. (2012). *Exploratory Factor Analysis*. Nueva York: Oxford University Press.

Forrester. (2023). *The future of personalization: How AI is reshaping the customer experience*. Forrester: <https://www.forrester.com/research/overview>

Galdos Frisancho, J. N. (2024). *Marketing interactivo, factores e influencia de los medios de comunicación interactiva sobre la intención de compra de los usuarios de entre 18 y 35 años residentes en Lima Metropolitana: Caso rubro de bienes tecnológicos portables*.

Gao, B., Wang, Y., Xie, H., & Hu, Y. (2023). Artificial Intelligence in Advertising: Advancements, Challenges, and Ethical Considerations in Targeting, Personalization, Content Creation, and Ad Optimization. *SAGE Open*, 13, 1-20.

- Gobierno de Chile. (2023). *Ley de Protección de Datos Personales aprobada en Chile*.
Gobierno de Chile: <https://www.gob.cl/noticias/ley-proteccion-datos-personales-aprobacion-eleva-estandar-derechos/>
- Goddard, A. (1998). *The Language of Advertising*. Routledge.
- Gómez Suárez, M., & Rozano Sáez, M. (2015). La estrategia del me-too: un producto similar con nombre distintivo colocado junto al líder. *Cuadernos de Administración*, 80-87.
- Ha, Y., & Lennon, S. J. (2010). Online visual merchandising (VMD) cues and consumer pleasure and arousal: Purchasing versus browsing situation. *Psychology & Marketing*, 141-165.
- Hrabovskyi, Y. (2021). Automation of forming complex advertising products. En K. Szymczyk, & I. M. El Emary, *Advanced trends in ICT for innovative business management* (págs. 69–86).
- IAB Chile. (2024). *Informe de Tendencias de Marketing de IAB Chile 2024*. IAB Chile.
- IAB Europe. (12 de Junio de 2024). *IAB Europe AdEx Benchmark Report 2023*. IAB Europe: https://iabeurope.eu/knowledge_hub/iab-europe-adex-benchmark-report-2023/
- IAB. (2024). *Internet Advertising Revenue Report 2024*. IAB: <https://www.iab.com/insights/internet-advertising-revenue-report-2024/>
- 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*, 62, 15–25.
- Karmakar, M. (2015). Consumer perception of privacy and personalization in online advertising: An empirical study. *Journal of Interactive Marketing*, 30, 42-57.
- Kasiri, L. A., Guan Cheng, K. T., Sambasivan, M., & Sidin, S. M. (2017). Integration of

- standardization and customization: Impact on service quality, customer satisfaction, and loyalty. *Journal of Retailing and Consumer Services*, 35(91–97).
- Kasiri, L. A., Guan Cheng, K. T., Sambasivan, M., & Sidin, S. M. (2017). Integration of standardization and customization: Impact on service quality, customer satisfaction, and loyalty. *Journal of Retailing and Consumer Services*, 35, 91–97.
- Kasiri, L. A., Guan Cheng, K. T., Sambasivan, M., & Sidin, S. M. (2017). Integration of standardization and customization: Impact on service quality, customer satisfaction, and loyalty. *Journal of Retailing and Consumer Services*.
- Khoros. (2022). *Social Media Trends 2023 Report*. Khoros: <https://khoros.com/press-release/2022/talkwalker-and-khoros-release-social-media-trends-2023-report>
- Kietzmann, J., Paschen, J., & Treen, E. (2018). Artificial intelligence in advertising: How marketers can leverage AI along the consumer journey. *Journal of Advertising Research*, 263-267.
- Lemon, K. N., & Verhoef, P. C. (2016). Understanding customer experience throughout the customer journey. *Journal of Marketing*, 80, 69–96.
- Liao, T., & Sundar, S. S. (2022). The robot made me do it: Human–machine communication and the psychology of algorithmic persuasion. *Journal of Computer-Mediated Communication*(27), 1–19 .
- McKinsey & Company. (2023). *The state of AI in 2023: Generative AI’s breakout year*. McKinsey & Company: <https://www.mckinsey.com/business-functions/mckinsey-digital/our-insights/the-state-of-ai-in-2023>
- Mehrabian, A. &. (1974). *An approach to environmental psychology*. MIT Press.
- Microsoft News Center. (2024). *El 93% de las PyMEs chilenas han invertido en tecnología para facilitar el trabajo remoto*. Microsoft News Center: <https://news.microsoft.com>.

- Muhammadian, R. (4 de Julio de 2020). *Artificial intelligence in marketing: How AI is revolutionizing digital marketing*. Theseus:
<https://www.theseus.fi/handle/10024/344493>
- Nikolajeva, A., & Teilans, A. (2021). Machine learning technology overview in terms of digital marketing and personalization. *Proceedings of the 35th International ECMS Conference on Modelling and Simulation*. European Council for Modeling and Simulation.
- Pappas, I. O., Kourouthanassis, P. E., Giannakos, M. N., & Chrissikopoulos, V. (2017). Sense and sensibility in personalized e-commerce: How emotions rebalance the purchase intention. *Electronic Commerce Research and Applications*, 25, 44–57.
- Peter, J. P., & Olson, J. C. (2006). *Comportamiento del consumidor y estrategia de marketing*. McGraw-Hill/Interamericana.
- Pizzi, G., Scarpi, D., & Pantano, E. (2021). Artificial intelligence and the new forms of interaction: Who has the control when interacting with a chatbot? . *Nombre de la revista*: , 878–890.
- Rane, N. L., Choudhary, S. P., & Rane, J. (2023). *Hyper-personalization for enhancing customer loyalty and satisfaction in Customer Relationship Management (CRM) systems*. SSRN.
- Richard, M. O. (2005). Modeling the impact of internet atmospherics on surfer behavior. *Journal of Business Research*, 1632-1642.
- Rocha, Á., Reis, J. L., Peter, M. K., & Bogdanović, Z. (2019). *Marketing and Smart Technologies*.
- Salesforce. (2024). *Salesforce Ranked #1 in CRM Market Share for Ninth Consecutive Year*. Salesforce: <https://www.salesforce.com>
- Salesforce. (2024). *Salesforce Ranked #1 in CRM Market Share for Ninth Consecutive*

Year. Salesforce: <https://www.salesforce.com>

Salgado Reyes, N. (2023). Uso de la inteligencia artificial en la personalización de la experiencia del usuario en plataformas digitales. *Pol. Con.*, 8(6), 1190-1206.

Schiffman, L. G., & Kanuk, L. L. (2010). *Comportamiento del consumidor*. Pearson Educación.

Schiffman, L., & Kanuk, L. (2005). *Comportamiento del consumidor*. Pearson Prentice Hall.

SCOPEN. (2023). *Agency Scope Chile 2023/24*. SCOPEN.

SCOPEN. (2023). *Informe anual de inversión publicitaria en Chile 2023*. SCOPEN: <https://www.scopen.com/chile-agency-scope-2023>

SEMrush. (2024). *93 estadísticas de publicidad online que debes conocer para 2024*.

SEMrush: <https://es.semrush.com/blog/publicidad-estadistica/>

Sicilia, M., Palazón, M., & López, M. (2016). Publicidad emocional y lealtad de marca. *Revista de Marketing Aplicado*, 12(3), 45-67.

Szymczyk, K., & El Emary, I. M. (2021). *Advanced trends in ICT for innovative business management*. CRC Press.

Tam, K. Y., & Ho, S. Y. (2006). Understanding the impact of web personalization on user information processing and decision outcomes. *MIS Quarterly*, 30, 865–890.

Turner, M., Kitchenham, B., Brereton, P., Charters, S., & Budgen, D. (2010). Does the technology acceptance model predict actual use? *Information and Software Technology*, 463-479.

Turner, M., Kitchenham, B., Brereton, P., Charters, S., & Budgen, D. (2010). Does the technology acceptance model predict actual use? *Information and Software Technology*, 463-479.

Turner, M., Kitchenham, B., Brereton, P., Charters, S., & Budgen, D. (2010). Does the

technology acceptance model predict actual use? *Information and Software Technology*, 463-479.

Urueña, A., Ferrari, A., Blanco, D., & Valdecasa, B. (2011). *El perfil del consumidor online en la era digital*. Editorial UOC.

Vásquez-Patiño, L. F., & Rueda-Barrios, G. E. (2019). El neuromarketing como estrategia de persuasión del consumidor: evolución teórica. *Revista Espacios*, 40(1), 25.

Venkatesh, V., & Davis, F. D. (2000). A theoretical extension of the technology acceptance model: Four longitudinal field studies. *Management Science*, 46(2), 186-204.

Xu, H., Teo, H. H., Tan, B. C., & Agarwal, R. (2020). The role of push–pull technology in privacy calculus: The case of location-based services. *Journal of Management Information Systems*, 26, 135–173.

Zhang, T. L. (2022). The impact of artificial intelligence on consumer behavior: Insights from the stimulus-organism-response framework. *Journal of Marketing Research*, 78-95.

Zúñiga Vásquez, F. G., Mora Poveda, D. A., & Llerena Llerena, W. V. (2023). El Big Data y su implicación en el marketing. *Revista de Comunicación de la SEECI*, 302-321.

Zúñiga Vásquez, F. G., Mora Poveda, D. A., & Molina Mora, D. P. (2023). La importancia de la inteligencia artificial en las comunicaciones en los procesos marketing. *Vivat Academia*, 19-39.