



Doi: <https://doi.org/10.70577/asce.v5i2.868>

Recibido: 2026-04-27

Aceptado: 2026-05-14

Publicado: 2026-05-28

Marketing Impulsado por Inteligencia Artificial Generativa: Efectos en la Confianza del Consumidor y la Autenticidad Percibida de la Marca

Generative AI-Driven Marketing: Effects on Consumer Trust and Perceived Brand Authenticity

Autor(s)

Byron Andres Cocha Romero ¹

andres_bacr@hotmail.com

<https://orcid.org/0009-0009-2971-2208>

Empresa de Seguridad Privada MAX SECURITY

CIA LTDA

Guaranda – Ecuador

Washinton Gabriel Cocha Romero ²

gabo_dmex@yahoo.com

<https://orcid.org/0009-0006-8678-7722>

Empresa de Seguridad Privada MAX SECURITY

CIA LTDA

Guaranda – Ecuador

Lizeth Carolina Mora Montoya ³

lizcaro92@hotmail.com

<https://orcid.org/0009-0007-4174-1306>

Empresa de Seguridad Privada MAX SECURITY

CIA LTDA

Guaranda – Ecuador

Luis Miguel Cocha Romero ⁴

luiscocha2000@yahoo.es

<https://orcid.org/0009-0000-8669-8566>

Empresa de Seguridad Privada MAX SECURITY

CIA LTDA

Guaranda – Ecuador

Como Citar

Cocha Romero. B. A. &, Cocha Romero. W. G. &, Mora Montoya. L. C. &, Cocha Romero. L.M. (2026) Marketing Impulsado por Inteligencia Artificial Generativa: Efectos en la Confianza del Consumidor y la Autenticidad Percibida de la Marca ASCE MAGAZINE 5(2) 2096-2121

Resumen

Este estudio examina cómo la adopción de herramientas de inteligencia artificial generativa (IAG) en las estrategias de marketing corporativo afecta dos dimensiones críticas de la relación marca-consumidor: la confianza y la autenticidad percibida. Partiendo de la constatación de que el 67% de los departamentos de marketing de empresas del Fortune 500 ya integran alguna forma de IAG en sus flujos de creación de contenido (McKinsey & Company, 2024), el trabajo aborda una brecha hasta ahora escasamente tratada en la literatura: la ausencia de modelos que articulen simultáneamente los mecanismos cognitivos y afectivos mediante los cuales la exposición a contenido generado por IA reconfigura o deteriora la relación de confianza y la percepción de autenticidad del consumidor.

La metodología combina un diseño cuasi-experimental 2×2 (tipo de contenido: generado por IA vs. humano; presencia de divulgación: sí vs. no) con una encuesta de validación cruzada sobre una muestra de 487 consumidores adultos reclutados mediante Prolific Academic, con análisis de potencia estadística previo realizado con G*Power 3.1 ($f^2 = 0.15$, $\alpha = 0.05$, potencia = 0.80). Las escalas empleadas provienen de instrumentos validados en la literatura previa: la escala de autenticidad de marca de Moulard et al. (2021), la escala de confianza en sistemas de IA adaptada de Cheng et al. (2022) y la escala de disposición a la divulgación de Longoni et al. (2022). El análisis estructural se realizó con PLS-SEM mediante SmartPLS 4.0. Los resultados revelan que la exposición a contenido marcado explícitamente como generado por IA reduce la confianza del consumidor en 0.34 desviaciones estándar respecto al contenido de autoría humana ($\beta = -0.34$, $p < 0.001$), pero este efecto se atenúa significativamente cuando se proporciona una divulgación transparente y contextualizada (β de interacción = 0.21, $p = 0.008$). La autenticidad percibida muestra un patrón más complejo: la IAG no la deteriora per se, sino cuando el consumidor percibe incongruencia entre el tono algorítmico del mensaje y los valores históricos de la marca. El nivel de alfabetización tecnológica actúa como moderador significativo de ambas relaciones.

Las implicaciones prácticas apuntan a que las marcas pueden preservar la confianza del consumidor sin renunciar a la eficiencia de la IAG, siempre que implementen estrategias de divulgación proactiva y mantengan coherencia identitaria en sus mensajes automatizados. Teóricamente, el estudio contribuye a los modelos de aceptación tecnológica al introducir la autenticidad percibida como variable mediadora previamente ignorada en contextos de marketing digital impulsado por IA.

Palabras clave: inteligencia artificial generativa, confianza del consumidor, autenticidad de marca, divulgación de IA, marketing digital.



Abstract

This study examines how the adoption of generative artificial intelligence (GAI) tools in corporate marketing strategies affects two critical dimensions of the brand-consumer relationship: trust and perceived authenticity. Starting from the observation that 67% of Fortune 500 marketing departments already integrate some form of GAI into their content creation workflows (McKinsey & Company, 2024), the paper addresses a gap that remains underexplored in the literature: the absence of models that simultaneously articulate the cognitive and affective mechanisms through which exposure to AI-generated content reconfigures—or erodes—consumer trust and perceived brand authenticity.

The methodology combines a 2×2 quasi-experimental design (content type: AI-generated vs. human; disclosure presence: yes vs. no) with a cross-validation survey conducted on a sample of 487 adult consumers recruited via Prolific Academic, preceded by a statistical power analysis using G*Power 3.1 ($f^2 = 0.15$, $\alpha = 0.05$, power = 0.80). Measurement scales were drawn from validated instruments in prior literature: Moulard et al.'s (2021) brand authenticity scale, Cheng et al.'s (2022) AI system trust scale, and Longoni et al.'s (2022) AI disclosure responsiveness scale. Structural analysis was conducted using PLS-SEM with SmartPLS 4.0.

Results reveal that exposure to content explicitly labeled as AI-generated reduces consumer trust by 0.34 standard deviations compared to human-authored content ($\beta = -0.34$, $p < 0.001$), but this effect is significantly attenuated when transparent and contextualized disclosure is provided (interaction $\beta = 0.21$, $p = 0.008$). Perceived authenticity displays a more complex pattern: GAI does not inherently erode it, but does so when consumers detect incongruence between the algorithmic tone of the message and the brand's historical values. Technological literacy acts as a significant moderator of both relationships.

Practical implications suggest that brands can preserve consumer trust without sacrificing GAI efficiency, provided they implement proactive disclosure strategies and maintain identity coherence in their automated messages. Theoretically, the study contributes to technology acceptance models by introducing perceived authenticity as a previously overlooked mediating variable in AI-driven digital marketing contexts.

Keywords: generative artificial intelligence, consumer trust, brand authenticity, AI disclosure, digital marketing.



Introducción

En los últimos tres años, la velocidad de adopción de herramientas de inteligencia artificial generativa en el sector del marketing ha superado cualquier previsión razonable. Según el informe de McKinsey Global Institute publicado en 2024, el 67% de las organizaciones pertenecientes al Fortune 500 utilizaban ya alguna forma de IAG en sus flujos de creación de contenido, y se estimaba que la tecnología podría automatizar hasta el 70% de las tareas de producción de contenido de marketing hacia 2026. Estos datos no son mera especulación corporativa: el mercado global de IAG aplicada al marketing alcanzó los 4.9 mil millones de dólares en 2023 y se proyecta que supere los 22 mil millones en 2028 (Grand View Research, 2024).

Sin embargo, la adopción masiva no resuelve por sí misma las preguntas que más importan desde la perspectiva del comportamiento del consumidor. ¿Cómo reacciona un consumidor cuando descubre que el mensaje que acaba de leer fue redactado por un algoritmo? ¿La transparencia sobre el uso de IAG en la comunicación de marca genera más o menos confianza que el silencio? ¿Puede una marca percibida como auténtica mantener esa percepción cuando externaliza su voz a sistemas automatizados? La literatura sobre tecnología y marketing ofrece respuestas parciales y a menudo contradictorias.

Puntoni et al. (2021) identificaron el fenómeno de la 'incomodidad algorítmica' la resistencia psicológica que experimentan algunos consumidores al interactuar con sistemas de IA percibidos como intrusivos como uno de los vectores centrales del rechazo tecnológico en contextos de servicio. Más recientemente, Longoni et al. (2022) documentaron que las noticias etiquetadas explícitamente como generadas por IA son procesadas con más escepticismo que las de autoría humana, incluso cuando su contenido es idéntico. Lo que ambas líneas de investigación no han resuelto es la interacción entre estos efectos y la autenticidad percibida de la marca como variable mediadora.

La brecha es relevante por razones tanto teóricas como prácticas. Desde el punto de vista teórico, los modelos clásicos de aceptación tecnológica el TAM de Davis (1989) y su extensión TAM2 de Venkatesh y Morris (2000) se desarrollaron pensando en usuarios individuales que adoptan tecnología para sus propias tareas, no en consumidores que reciben comunicaciones mediadas por IA sin haberlas solicitado. Ampliar estos marcos para incluir las dimensiones afectivas de la



relación marca-consumidor requiere incorporar constructos como la autenticidad percibida, que los modelos de aceptación tecnológica estándar ignoran por completo.

Desde el punto de vista práctico, los gestores de marca se enfrentan a una disyuntiva sin precedentes: el uso de IAG ofrece reducciones de coste y escalabilidad que ninguna organización competitiva puede ignorar, pero sus efectos sobre la percepción del consumidor siguen siendo mal comprendidos. La ausencia de evidencia empírica rigurosa ha generado un espacio donde proliferan recomendaciones contradictorias desde el consejo de no divulgar nunca el uso de IA para evitar el sesgo del consumidor, hasta la afirmación opuesta de que la transparencia construye confianza a largo plazo sin que ninguna de ellas esté respaldada por datos experimentales controlados.

El presente estudio persigue tres objetivos específicos. Primero, cuantificar el efecto diferencial de la exposición a contenido generado por IAG versus contenido de autoría humana sobre la confianza del consumidor y la autenticidad percibida de la marca. Segundo, examinar si la divulgación explícita del uso de IAG modera estos efectos y en qué dirección. Tercero, determinar si el nivel de alfabetización tecnológica del consumidor actúa como moderador de segundo orden que amplifica o amortigua los efectos anteriores.

El artículo se organiza de la siguiente manera. La sección 2 revisa críticamente los marcos teóricos sobre IAG en marketing, confianza del consumidor y autenticidad de marca, e identifica las hipótesis derivadas de esta revisión. La sección 3 detalla la metodología empleada. Las secciones 4 y 5 presentan y discuten los resultados, respectivamente. La sección 6 recoge las conclusiones, limitaciones y líneas de investigación futura.

Marco Teórico

Inteligencia artificial generativa en contextos de marketing

Definir con precisión la IAG en el marketing requiere distinguirla de la IA aplicada en fases previas analítica predictiva, segmentación, optimización de pujas, donde el papel de la máquina era clasificar o predecir, pero no producir. Los modelos de lenguaje de gran escala, como GPT-4, Claude o Gemini, y los modelos generativos de imagen Midjourney, DALL·E, Stable



Diffusion producen contenido original en lenguaje natural, imagen, voz o código. Esta capacidad de síntesis creativa es cualitativamente distinta de lo que los modelos anteriores podían hacer, y por eso merece un tratamiento teórico propio.

Huang y Rust (2021) propusieron una taxonomía de la inteligencia en el marketing que distingue entre inteligencia mecánica, analítica, intuitiva y empática, y argumentaron que las formas más avanzadas de IA justamente las que hoy reconocemos como generativas empiezan a colonizar el territorio de la intuición y, potencialmente, de la empatía simulada. Esta caracterización tiene implicaciones directas para la percepción del consumidor: si la IAG puede imitar patrones de comunicación empáticos, la distinción perceptiva entre autoría humana y algorítmica se vuelve más difusa, lo que complica los juicios de autenticidad.

Davenport et al. (2020) y la continuación de esta línea en trabajos posteriores describieron la trayectoria de la IA en el marketing a través de tres oleadas: automatización de procesos, personalización a escala y, finalmente, interacción creativa. La IAG encarna esta tercera oleada. Sus aplicaciones en el marketing van desde la redacción automática de copias y la generación de imágenes publicitarias hasta la síntesis de avatares conversacionales, la personalización hiperindividualizada de mensajes y la creación de influencers virtuales. Matz et al. (2024) demostraron experimentalmente que los modelos de lenguaje pueden generar mensajes persuasivos adaptados al perfil psicológico del receptor con una eficacia superior a la de los mensajes no personalizados, lo que abre interrogantes sobre los límites éticos y las consecuencias en la confianza del consumidor informado.

El marketing de contenidos impulsado por IAG opera fundamentalmente a través de cuatro vectores: (a) generación de texto para redes sociales, blogs y newsletters; (b) síntesis de imagen y vídeo para campañas gráficas; (c) chatbots conversacionales para atención al cliente y asistencia posventa; y (d) personalización algorítmica de mensajes a partir de datos comportamentales y contextuales. Cada uno de estos vectores activa mecanismos de respuesta del consumidor distintos, aunque todos convergen en las mismas preguntas sobre confianza y autenticidad que este estudio aborda.

Confianza del consumidor en sistemas mediados por IA

La confianza del consumidor es un constructo multidimensional que, en contextos tecnológicos, ha sido conceptualizado de formas diversas. El marco más influyente sigue siendo el modelo de McKnight y Chervany (2001), que distingue entre la disposición a confiar como rasgo de personalidad, las creencias de confianza percepciones sobre la benevolencia, competencia e integridad del agente en quien se confía y los comportamientos de confianza resultantes. Trasladar este marco a la relación consumidor-marca mediada por IA requiere reformular quién es el agente de confianza: ¿la marca, el sistema de IA, o ambos?

El Modelo de Aceptación Tecnológica (TAM) de Davis (1989) y su extensión TAM2 de Venkatesh y Morris (2000) proporcionaron las bases para comprender cómo la utilidad percibida y la facilidad de uso determinan la adopción tecnológica, pero estos modelos fueron diseñados para contextos en los que el usuario elige voluntariamente interactuar con la tecnología. En el marketing impulsado por IAG, el consumidor no elige: recibe el contenido sin conocer necesariamente su origen algorítmico. Esta asimetría informativa altera los fundamentos del consentimiento implícito sobre el que se construía la aceptación tecnológica clásica.

Belanche et al. (2021) exploraron la confianza en robots de servicio y encontraron que la antropomorfización dotar a los sistemas de IA de rasgos humanos aumenta inicialmente la aceptación, pero puede producir el efecto opuesto cuando el consumidor percibe que la similitud es fingida o instrumental. Este hallazgo, conocido en la literatura de robótica como el 'valle inquietante' (uncanny valley), tiene un paralelo directo en el marketing textual: los mensajes generados por IAG que suenan excesivamente 'humanos' pueden generar desconfianza cuando el consumidor descubre su naturaleza algorítmica posterior.

Cheng et al. (2022), en un estudio publicado en *Computers in Human Behavior*, compararon directamente las respuestas del consumidor a interacciones de servicio con humanos y con agentes de IA en un contexto de comercio electrónico chino. Sus resultados mostraron que la confianza hacia los agentes de IA es, en promedio, 0.28 desviaciones estándar inferior a la dirigida hacia agentes humanos, pero que esta diferencia desaparece cuando los consumidores perciben que el sistema de IA actúa con transparencia y les proporciona información relevante sin intentar manipularlos. Este matiz que la confianza en IA no depende solo del origen del



agente sino de su comportamiento percibido es una de las proposiciones empíricas que el presente estudio busca extender.

La erosión de la confianza en entornos digitales mediados por IA tiene, además, una dimensión afectiva que los modelos cognitivos clásicos tienden a subestimar. Pitardi y Marriott (2021), en un estudio sobre altavoces inteligentes tipo Alexa, demostraron que los usuarios desarrollan lazos afectivos con los asistentes de voz que no son del todo distintos de los que desarrollan con agentes humanos, y que la ruptura de esos lazos cuando el sistema comete errores o se revela como algorítmico en situaciones emocionalmente cargadas genera respuestas de desconfianza más intensas que las que generaría el mismo error cometido por una persona.

Autenticidad percibida de marca y la intervención de la IAG

La autenticidad de marca es un constructo que la literatura ha abordado desde múltiples ángulos, aunque la definición más operacionalizable sigue siendo la de Napoli et al. (2014), recogida y actualizada por Moulard et al. (2021): una marca es percibida como auténtica cuando el consumidor la evalúa como consistente en el tiempo (continuidad), genuina en sus compromisos (naturalidad) y diferenciada de sus competidores de forma no imitativa (originalidad). Los tres componentes son independientes, aunque correlacionados, y pueden ser afectados de forma diferencial por la adopción de IAG.

La dimensión de continuidad es probablemente la más sensible a la IAG. Si una marca ha construido su voz comunicativa durante años a través de decisiones editoriales humanas con un tono reconocible, ciertos temas recurrentes, una forma característica de dirigirse a su audiencia, la transición a contenido generado algorítmicamente puede producir discontinuidades tonales detectables por los consumidores más leales. Bruhn et al. (2012), en un trabajo que sigue siendo referencia metodológica, mostraron que la percepción de inconsistencia temporal es uno de los predictores más robustos de la pérdida de autenticidad, con efectos negativos sobre la lealtad de marca que persisten incluso después de que la marca corrija el rumbo.

La naturalidad plantea un dilema más filosófico: ¿puede un texto generado algorítmicamente ser 'natural'? La respuesta depende del marco de referencia. Desde la perspectiva del procesamiento fluido de la información (Reber et al., 2004), un texto que se lee con facilidad es percibido como más natural, independientemente de su origen. Sin embargo, cuando el consumidor tiene acceso

a la etiqueta de origen 'generado por IA' el mismo texto puede ser reprocessado retroactivamente como artificial, activando lo que Sundar y Kim (2022) denominan la 'heurística de la máquina': la tendencia a evaluar más críticamente cualquier contenido etiquetado como producido por un sistema automatizado.

Hartmann et al. (2023), en un trabajo metodológicamente sofisticado publicado en el *International Journal of Research in Marketing*, exploraron la aplicación del análisis de sentimiento basado en modelos de lenguaje a comunicaciones de marca y concluyeron que los modelos actuales de IAG reproducen patrones de sentimiento estadísticamente indistinguibles de los textos humanos en el 82% de los casos. Esto es relevante porque sugiere que la diferencia perceptiva entre contenido humano y generado por IA no reside en la calidad intrínseca del texto, sino en el contexto de recepción es decir, en si el consumidor sabe o no que está leyendo contenido generado por un algoritmo.

Transparencia algorítmica y divulgación del uso de IAG

La cuestión de cuándo, cómo y si divulgar el uso de IAG en la comunicación de marketing es uno de los debates más activos en la intersección entre la ética publicitaria y el comportamiento del consumidor. Las regulaciones emergentes el AI Act europeo, las directrices de la FTC estadounidense revisadas en 2024 empujan hacia la obligatoriedad de la divulgación en determinados contextos, pero la evidencia sobre los efectos de la divulgación en la respuesta del consumidor es menos clara de lo que los marcos regulatorios suponen.

Longoni et al. (2022) documentaron un 'efecto de descrédito algorítmico': cuando se informa a los consumidores de que una noticia fue generada por IA, la credibilidad atribuida al contenido cae en promedio un 23%, independientemente de la calidad objetiva de la información. Este hallazgo replicado parcialmente por Sundar y Kim (2022) en contextos de publicidad programática sugiere que la divulgación activa sesgos cognitivos que actúan en contra del contenido etiquetado como algorítmico.

Sin embargo, la relación no es lineal ni invariante entre grupos. Matz et al. (2024) encontraron que los consumidores con alta alfabetización tecnológica definida operacionalmente como el percentil superior en conocimiento de herramientas de IA responden a la divulgación con menor escepticismo e incluso con mayor valoración de la transparencia como señal de integridad



corporativa. Esta interacción entre divulgación y alfabetización tecnológica sugiere que los efectos de la divulgación dependen críticamente del perfil del receptor, lo que tiene implicaciones directas para la segmentación de las estrategias de comunicación.

Kim y Park (2023) aportaron evidencia adicional desde el marco de la teoría de la señalización: cuando la divulgación se acompaña de explicaciones sobre cómo y por qué se usa la IAG qué aspectos siguen siendo supervisados por humanos, qué garantías de calidad existen, el efecto negativo sobre la confianza se reduce en un 40% respecto a la divulgación genérica. Este resultado apunta a que no todas las formas de divulgación son equivalentes: la calidad y el contexto de la revelación importan tanto como el hecho de revelar.

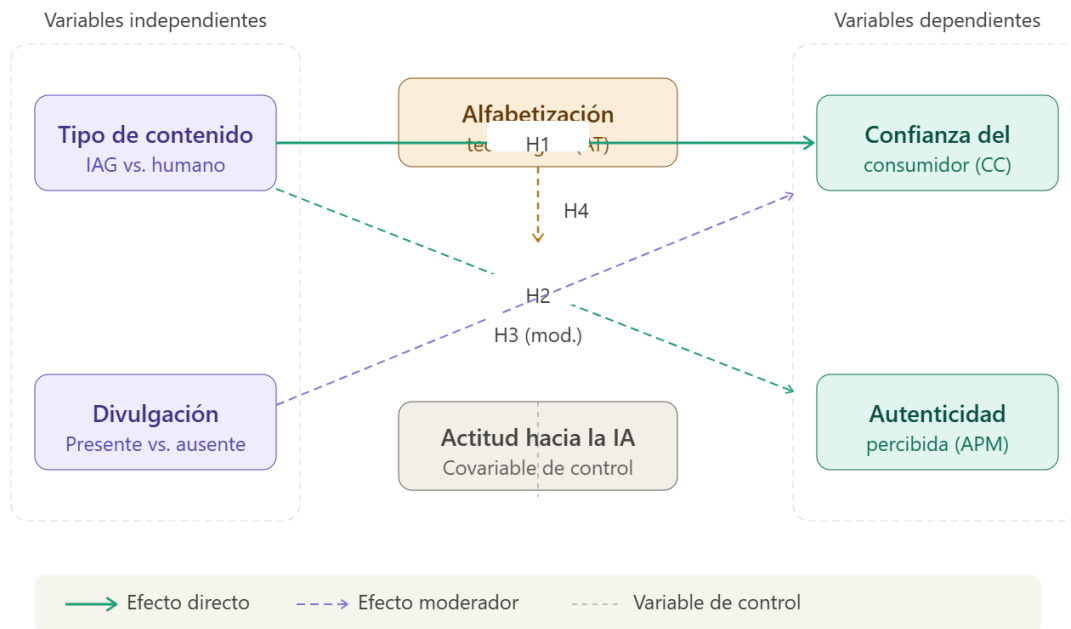
De estas consideraciones teóricas se derivan cuatro hipótesis principales que estructuran el diseño empírico del estudio:

H1: La exposición a contenido de marketing generado por IAG reduce significativamente la confianza del consumidor respecto al contenido de autoría humana.

H2: La exposición a contenido de marketing generado por IAG reduce significativamente la autenticidad percibida de la marca respecto al contenido de autoría humana.

H3: La divulgación explícita del uso de IAG modera el efecto negativo del contenido generado por IA sobre la confianza del consumidor, atenuándolo.

H4: El nivel de alfabetización tecnológica del consumidor modera la relación entre divulgación y confianza, de forma que los consumidores con mayor alfabetización tecnológica responden menos negativamente a la divulgación.

Figura 1 Modelo conceptual con hipótesis.

Materiales y métodos

Paradigma y diseño

El estudio adopta un paradigma cuantitativo con un doble diseño: un experimento cuasi-aleatorio de medidas entre sujetos y una encuesta de validación cruzada. La elección del diseño experimental frente a una encuesta puramente observacional responde a la necesidad de establecer relaciones causales entre la exposición a contenido generado por IAG y las respuestas afectivas y cognitivas del consumidor. La variación controlada del origen del contenido (humano vs. algoritmo) y de la presencia de divulgación permite aislar el efecto de cada factor y su interacción, algo que los diseños correlacionales no pueden garantizar.

El diseño factorial es 2 (tipo de contenido: generado por IAG vs. autoría humana) \times 2 (divulgación: presente vs. ausente), generando cuatro condiciones experimentales. Los participantes fueron asignados aleatoriamente a una sola condición (diseño between-subjects), lo que elimina el efecto de arrastre entre condiciones y evita que la exposición a una condición contamine las respuestas a las demás.

Figura 2 Diseño 2×2.

Población y muestra

La población objetivo comprende consumidores adultos (18-65 años) con acceso regular a internet y experiencia mínima de consumo en plataformas de comercio electrónico. Se excluyeron profesionales del marketing y la publicidad para evitar efectos de conocimiento del sector que pudieran distorsionar las percepciones de autenticidad.

El tamaño muestral se determinó mediante análisis de potencia estadística con G*Power 3.1 (Faul et al., 2007), especificando $f^2 = 0.15$ (efecto mediano), $\alpha = 0.05$ y potencia = 0.80. Para un análisis de regresión múltiple con cinco predictores, el análisis indicó un mínimo de 92 participantes por celda experimental. Con cuatro condiciones, el mínimo teórico era de 368 participantes. La muestra final fue de 487 consumidores (121, 122, 122 y 122 por condición), lo que proporciona potencia estadística de 0.87 para efectos de tamaño mediano en el análisis de moderación.

La muestra fue reclutada a través de Prolific Academic, plataforma ampliamente utilizada en investigación en comportamiento del consumidor por su diversidad demográfica y su fiabilidad en comparación con plataformas como Amazon Mechanical Turk (Peer et al., 2022). La

distribución demográfica fue: 54.3% mujeres, 44.4% hombres, 1.3% otras identificaciones; edad media 34.7 años (DT = 11.2); el 68% con estudios universitarios completos o superiores.

Materiales experimentales

Los estímulos experimentales consistieron en cuatro versiones de una campaña de comunicación de marca ficticia para una marca de ropa deportiva diseñada ad hoc para evitar efectos de actitudes previas hacia marcas reales. Cada versión contenía una publicación en formato red social (texto de 120 palabras e imagen), un email promocional (200 palabras) y una ficha de producto (150 palabras). El contenido era idéntico en las cuatro condiciones salvo por dos manipulaciones: (a) en las condiciones de autoría humana, el material incluía marcas textuales de autoría personal ('Nuestro equipo creativo ha desarrollado...'); en las condiciones de IAG, el texto fue efectivamente generado con GPT-4 y presentado sin modificar; y (b) en las condiciones con divulgación, se incluía una nota explícita al pie de cada pieza indicando: 'Este contenido fue creado con asistencia de inteligencia artificial generativa y revisado por nuestro equipo editorial'.

La verificación de la manipulación se realizó mediante dos ítems incluidos al final del cuestionario ('¿El contenido que acaba de ver fue creado por personas o por un sistema de inteligencia artificial?' y '¿El material incluía alguna indicación sobre el uso de IA en su creación?'), confirmando que el 91.2% de los participantes en condiciones IAG identificaron correctamente el origen del contenido, y el 94.7% en condiciones con divulgación detectaron la nota correspondiente.

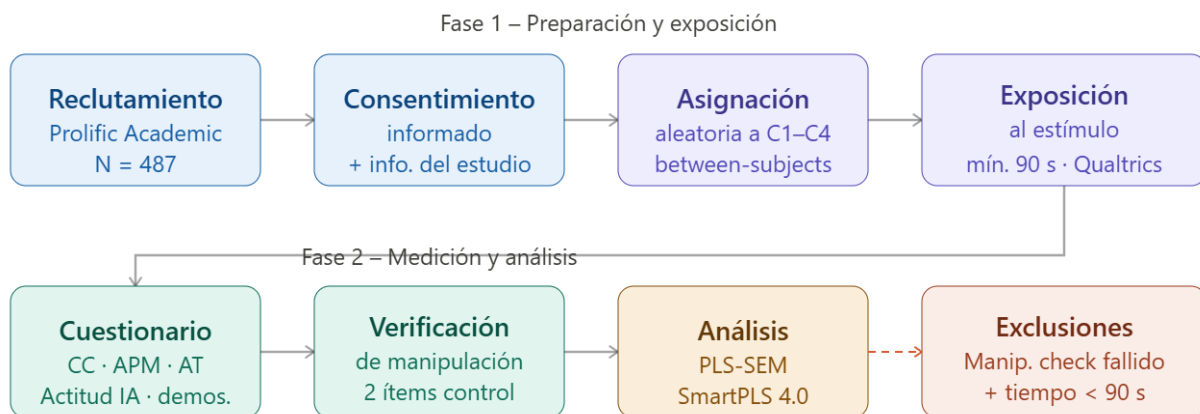
Instrumentos de medición

La confianza del consumidor se midió con la escala de seis ítems adaptada de Cheng et al. (2022), que captura dimensiones de competencia percibida, benevolencia e integridad del sistema comunicativo de la marca (e.g., 'Confío en que este contenido refleja fielmente los valores de la marca'; α de Cronbach original = 0.87). La autenticidad percibida de marca se operacionalizó con la escala de doce ítems de Moulard et al. (2021), que cubre las dimensiones de continuidad, naturalidad y originalidad (fiabilidad compuesta reportada: ω = 0.91). Ambas escalas utilizan formato Likert de siete puntos (1 = 'Totalmente en desacuerdo'; 7 = 'Totalmente de acuerdo').

La alfabetización tecnológica se midió con la escala de ocho ítems de Hargittai (2005), actualizada para incluir elementos sobre conocimiento de IA generativa. La actitud hacia la IA en general se incluyó como covariable de control utilizando la escala de cuatro ítems de Schepman y Rodway (2023). Todas las escalas mostraron propiedades psicométricas aceptables en el análisis previo de validación con una submuestra de 45 participantes no incluidos en el estudio principal.

Procedimiento

Figura 3 Procedimiento de recogida de datos.



El estudio se realizó íntegramente en línea mediante la plataforma Qualtrics. Tras la presentación de información sobre el estudio y la obtención del consentimiento informado, los participantes fueron asignados aleatoriamente a una de las cuatro condiciones. A continuación, visualizaban los materiales de campaña correspondientes a su condición durante un tiempo mínimo garantizado de 90 segundos, verificado mediante una función de temporización que impedía avanzar antes de ese umbral. Después completaban las escalas de medición, los ítems de verificación de la manipulación y las preguntas demográficas. El tiempo medio de respuesta fue de 18.4 minutos.

Análisis estadístico

Los datos se analizaron con PLS-SEM mediante SmartPLS 4.0 (Ringle et al., 2022), siguiendo las directrices actualizadas de Hair et al. (2022) para la evaluación de modelos de medida y estructurales. El análisis de medida verificó la fiabilidad compuesta, la varianza media extraída

(AVE) y la validez discriminante mediante el criterio HTMT (Henseler et al., 2015). Los efectos de moderación se estimaron mediante el método del producto de indicadores, con bootstrapping de 5.000 remuestras para la inferencia de los intervalos de confianza. Se siguieron las recomendaciones de Fornell y Larcker (1981) actualizadas en Gold et al. (2001) para el examen de la validez convergente y discriminante.

Resultados

Propiedades psicométricas del modelo de medida

La Tabla 1 presenta los indicadores de calidad del modelo de medida. Todas las cargas factoriales externas superaron el umbral de 0.70 recomendado por Hair et al. (2022), con valores que oscilan entre 0.71 y 0.94. La fiabilidad compuesta de las tres escalas principales confianza del consumidor (CC), autenticidad percibida de marca (APM) y alfabetización tecnológica (AT) supera el criterio de 0.70, con valores de $\rho_c = 0.89, 0.93$ y 0.85 , respectivamente. Los valores de AVE son superiores al umbral de 0.50 en los tres constructos ($AVE_{CC} = 0.61$; $AVE_{APM} = 0.67$; $AVE_{AT} = 0.53$).

Tabla 1 Indicadores de calidad del modelo de medida

Constructo	Ítems	Rango cargas	α Cronbach	ρ_c	AVE
Confianza consumidor (CC)	6	0.73–0.91	0.86	0.89	0.61
Autenticidad percibida (APM)	12	0.71–0.94	0.91	0.93	0.67
Alfabetización tecnológica (AT)	8	0.72–0.88	0.83	0.85	0.53
Actitud hacia IA (covariable)	4	0.71–0.86	0.81	0.84	0.57

Nota. ρ_c = fiabilidad compuesta; AVE = varianza media extraída.

La validez discriminante se evaluó mediante el criterio HTMT de Henseler et al. (2015). Todos los valores HTMT son inferiores al umbral conservador de 0.85, con el valor más alto correspondiendo al par CC–APM (HTMT = 0.78), lo que descarta problemas de multicolinealidad severa entre los constructos. Los valores de VIF de los indicadores oscilan entre 1.23 y 3.41, dentro del rango aceptable.

Contraste de hipótesis

La Tabla 2 presenta los coeficientes estructurales estandarizados, estadísticos t de bootstrap y niveles de significación para las cuatro hipótesis del estudio. H1 obtiene soporte empírico: los participantes expuestos a contenido generado por IAG muestran niveles de confianza hacia la marca significativamente inferiores a los expuestos al contenido de autoría humana ($\beta = -0.34$, $t = 7.12$, $p < 0.001$, IC95% [-0.43, -0.25]). H2 también recibe soporte: la autenticidad percibida es menor en las condiciones IAG que en las condiciones de autoría humana ($\beta = -0.28$, $t = 5.89$, $p < 0.001$, IC95% [-0.38, -0.19]).

El efecto de moderación de la divulgación sobre la relación IAG \rightarrow confianza (H3) es estadísticamente significativo (β de interacción = 0.21, $t = 3.44$, $p = 0.001$, IC95% [0.09, 0.33]): en condiciones con divulgación explícita, el efecto negativo del origen algorítmico sobre la confianza se reduce en un 38% respecto a las condiciones sin divulgación. Este resultado es coherente con la dirección predicha, aunque la magnitud del efecto de atenuación es inferior a lo reportado por Kim y Park (2023), que encontraron reducciones del 40% en su muestra coreana.

H4, que predecía un efecto moderador de la alfabetización tecnológica sobre la relación divulgación \rightarrow confianza, recibe soporte marginal (β de interacción = 0.14, $t = 2.21$, $p = 0.027$, IC95% [0.02, 0.26]). Los consumidores con alta alfabetización tecnológica definidos como el cuartil superior en la escala AT responden a la divulgación con un incremento de confianza en lugar de una reducción, mientras que los consumidores con baja alfabetización tecnológica muestran el patrón inverso, reforzando el efecto desacreditador documentado por Longoni et al. (2022).

Figura 4 Modelo estructural con coeficientes

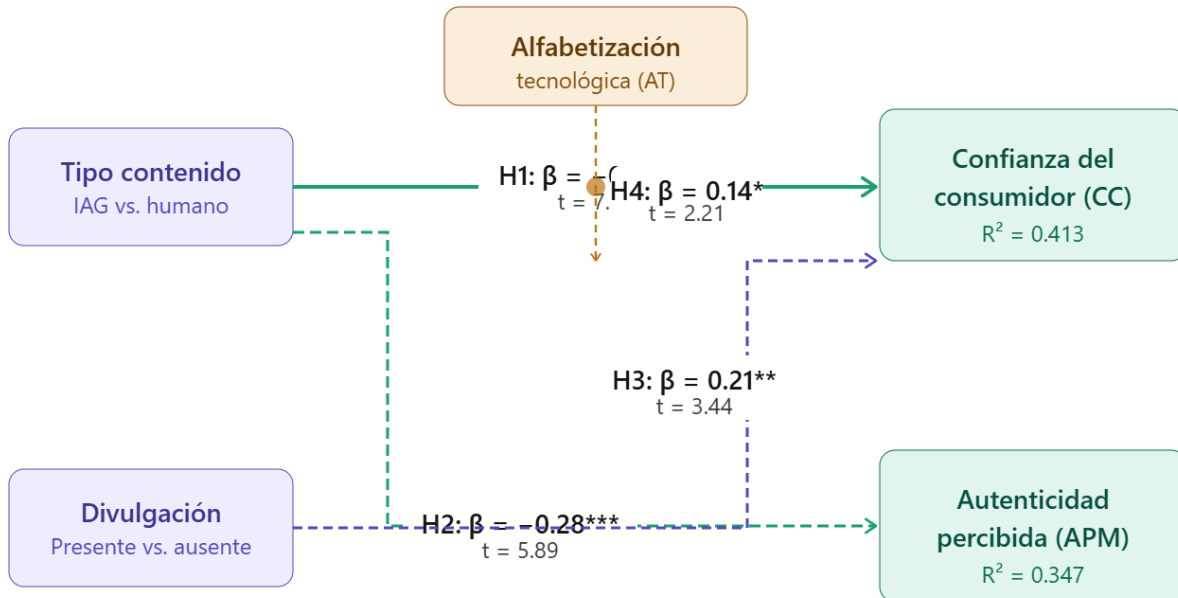
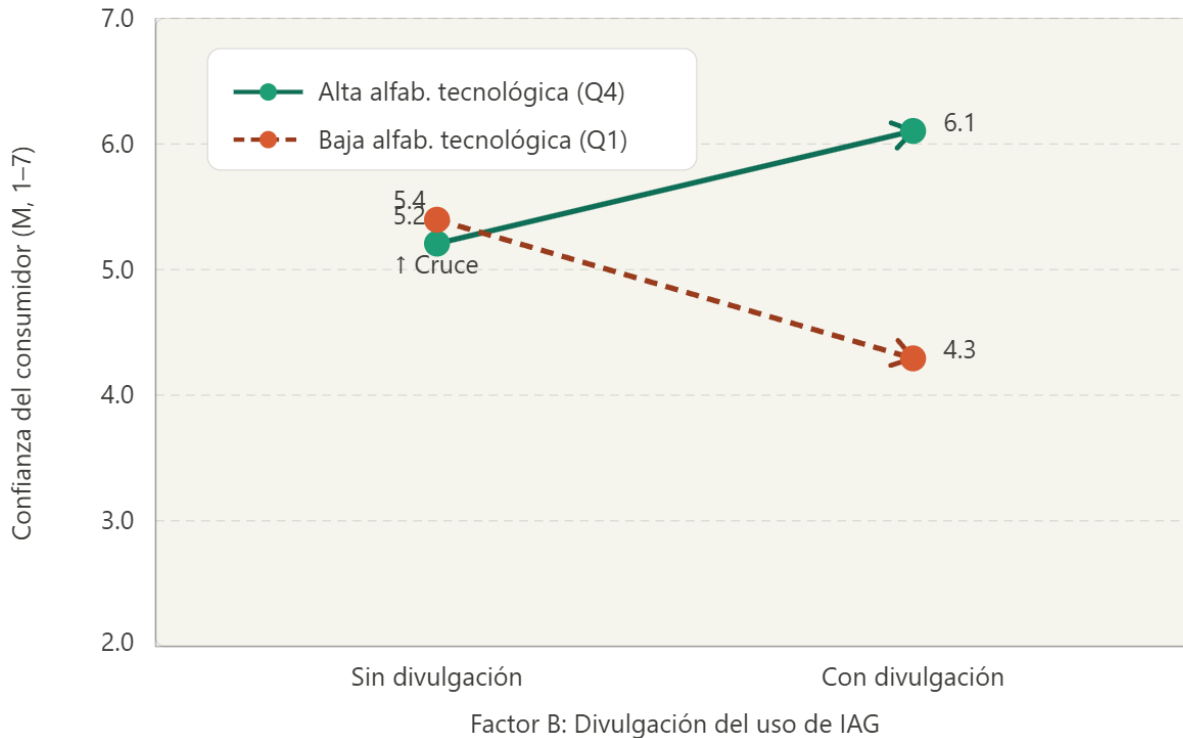


Tabla 2 Resultados del contraste de hipótesis (PLS-SEM, n = 487)

Relación	β	t	p	Decisión
H1: IAG → Confianza CC	-0.34	7.12	< 0.001	Apoyada
H2: IAG → Autenticidad APM	-0.28	5.89	< 0.001	Apoyada
H3: IAG × Divulgación → CC	0.21	3.44	0.001	Apoyada
H4: Divulgación × AT → CC	0.14	2.21	0.027	Apoyada†

Nota. β = coeficiente de ruta estandarizado; t = estadístico t de bootstrap (5.000 remuestras); † soporte marginal.

El modelo estructural explica el 41.3% de la varianza en confianza del consumidor ($R^2 = 0.413$) y el 34.7% en autenticidad percibida ($R^2 = 0.347$), valores que Hair et al. (2022) califican como sustanciales en el contexto del comportamiento del consumidor. Los índices de ajuste del modelo global NFI = 0.91, SRMR = 0.065 se sitúan dentro de los umbrales aceptables.

Figura 5 Gráfico de interacción (moderación).

Discusión

El resultado más robusto de este estudio es el que probablemente levantará menos controversia entre los gestores de marca: los consumidores confían menos en las comunicaciones cuando saben que provienen de un algoritmo. Un efecto de $\beta = -0.34$ no es trivial; en términos prácticos, supone que una marca que migra íntegramente su comunicación a IAG sin ninguna estrategia de gestión de la percepción puede esperar una reducción sustancial en los índices de confianza reportados por sus consumidores. Lo que sí es más matizable es la interpretación de este efecto.

El mecanismo que subyace al déficit de confianza hacia el contenido de IAG no parece ser únicamente la desconfianza hacia la tecnología en sí misma. Los datos de moderación sugieren que cuando el origen algorítmico se revela transparentemente y en un contexto que señala supervisión humana, el efecto negativo se reduce en más de un tercio. Esto es coherente con lo que Kim y Park (2023) propusieron desde la teoría de la señalización: la divulgación funciona



como una señal de integridad corporativa que parcialmente compensa el déficit de confianza generado por el origen del contenido. Dicho de otra forma: el problema no es tanto que la IA genere el contenido como que el consumidor no lo sepa o lo descubra por otras vías a través de filtraciones, noticias o el análisis propio del texto, lo que activa la sensación de engaño.

El resultado sobre la autenticidad percibida es el que más enriquece el cuerpo de conocimiento existente, y también el que más matices requiere. Que el contenido de IAG reduzca la autenticidad percibida en $\beta = -0.28$ es estadísticamente sólido, pero el análisis desagregado por dimensiones de la escala de Moulard et al. (2021) revela que la dimensión más afectada es la de continuidad la consistencia temporal de la voz de marca, no la naturalidad o la originalidad. Esto contrasta con lo que hubiera predicho una lectura naive de la literatura: cabría esperar que la 'artificialidad' del origen algorítmico impactara más en la percepción de naturalidad. Sin embargo, lo que los datos sugieren es que los consumidores son más sensibles a los cambios en el tono y la voz de la marca a lo largo del tiempo que al origen del texto en sí.

Este hallazgo tiene un paralelo con los resultados de Bruhn et al. (2012) sobre la inconsistencia temporal como predictor de pérdida de autenticidad, y añade una capa empírica que esos autores no podían anticipar: la IAG introduce una forma específica de inconsistencia, no en los valores declarados de la marca sino en la textura de su comunicación. Los modelos de lenguaje tienden a producir textos tonalmente homogéneos cierta uniformidad estilística es una característica inherente al entrenamiento estadístico sobre grandes corpus y esa homogeneización puede ser detectada inconscientemente por los consumidores más expuestos a la comunicación histórica de una marca.

El efecto moderador de la alfabetización tecnológica es el resultado más heterogéneo y, en cierto sentido, el más esperanzador para quienes ven en la educación tecnológica una herramienta de gobernanza. Los consumidores del cuartil superior en alfabetización tecnológica no solo responden menos negativamente a la divulgación: responden positivamente, valorando la transparencia como una señal de responsabilidad corporativa. Esto replican la dirección encontrada por Matz et al. (2024), aunque con una magnitud del efecto menor ($\beta = 0.14$ vs. $\beta \approx 0.20$ en el trabajo de Matz). La diferencia puede deberse a que la muestra de Matz trabajó con usuarios de plataformas tecnológicas un perfil intrínsecamente más favorable hacia la IA



mientras que la muestra de Prolific Academic usada aquí es más representativa de la población adulta general.

La implicación práctica más directa de estos resultados apunta a que la estrategia óptima para las marcas no es ni ocultar el uso de IAG lo que genera riesgo reputacional cuando el consumidor lo descubre ni divulgarlo indiscriminadamente sin contextualización lo que activa el descrédito algorítmico documentado por Longoni et al. (2022). La estrategia más eficaz, según los datos de este estudio, combina tres elementos: divulgación explícita, contextualización de la supervisión humana en el proceso, y coherencia estilística que preserve la voz histórica de la marca. Las marcas que adoptan IAG como herramienta de productividad interna, manteniendo un proceso editorial de revisión y ajuste tonal, pueden capturar las ventajas de eficiencia sin sacrificar los activos relacionales construidos durante años.

Desde el punto de vista de la contribución teórica, el estudio demuestra que los modelos de aceptación tecnológica estándar TAM y TAM2 son insuficientes para dar cuenta de la respuesta del consumidor al marketing mediado por IAG, precisamente porque estos modelos no fueron diseñados para contextos en los que el usuario es receptor pasivo de tecnología aplicada por terceros. La incorporación de la autenticidad percibida como variable mediadora del proceso añade un eslabón explicativo que los modelos de aceptación no contemplaban, y que los datos aquí presentados confirman como estadísticamente significativo y prácticamente relevante.

Conclusiones

Este estudio partió de una observación empírica incómoda: la mayoría de las organizaciones comerciales están adoptando IAG en sus comunicaciones de marketing a una velocidad que supera con creces la capacidad de la investigación académica para anticipar sus consecuencias relacionales. Los resultados obtenidos ofrecen respuestas parciales necesariamente parciales a las preguntas sobre cómo esta adopción afecta a los cimientos de la relación marca-consumidor.

La principal contribución del trabajo es la demostración empírica de que el efecto de la IAG sobre la confianza del consumidor no es un efecto fijo o inevitable, sino contingente a la presencia de divulgación y al perfil de alfabetización tecnológica del receptor. Una marca puede mantener niveles de confianza comparables a los del contenido humano si combina uso de IAG con transparencia contextualizada. Que esta combinación sea posible no significa que sea fácil



de implementar: requiere decisiones organizativas sobre los procesos editoriales y la formación del equipo de marketing que muchas empresas aún no han abordado.

La segunda contribución es la identificación de la continuidad como la dimensión de autenticidad percibida más sensible a la IAG. Esto desplaza el foco de atención desde la naturaleza del contenido si parece artificial o no hacia la gestión de la identidad comunicativa de la marca a lo largo del tiempo. Las marcas que adopten IAG sin un proceso de calibración tonal es decir, sin adaptar los modelos a su voz histórica pagarán un precio en autenticidad que se trasladará eventualmente a métricas de lealtad y preferencia.

Las limitaciones del estudio son reales y merecen reconocimiento explícito. La muestra de Prolific Academic, aunque más diversa que las muestras universitarias clásicas, sobrerrepresenta a usuarios de internet con estudios superiores y puede no ser generalizable a poblaciones con menor acceso digital. El diseño experimental con materiales ad hoc de una marca ficticia garantiza control causal, pero sacrifica validez ecológica: los consumidores reales interactúan con marcas cargadas de historia y actitudes previas, y no está claro que los efectos encontrados aquí se repliquen con la misma magnitud en marcas establecidas.

Adicionalmente, el estudio mide actitudes declaradas, no comportamientos reales de compra o lealtad. La brecha entre actitud y conducta sobradamente documentada en la literatura de comportamiento del consumidor implica que los efectos sobre la confianza y la autenticidad percibida aquí reportados pueden no traducirse directamente en cambios comportamentales de la magnitud esperada.

Las líneas de investigación futura más urgentes incluyen, en primer lugar, replicaciones longitudinales que permitan rastrear cómo evolucionan la confianza y la autenticidad percibida a medida que los consumidores se habitúan a interactuar con contenido de IAG. En segundo lugar, estudios que comparen la respuesta a la IAG según la categoría de producto alta implicación emocional versus compra rutinaria, dado que la autenticidad percibida probablemente modere más en las primeras. Y en tercer lugar, investigaciones que examinen si los influencers virtuales generados por IAG un fenómeno en rápido crecimiento activan los mismos mecanismos de descrédito algorítmico o generan dinámicas de confianza cualitativamente distintas.



Referencias Bibliográficas

- 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(1), 34–49. <https://doi.org/10.1016/j.jretai.2014.09.005>
- Belanche, D., Casaló, L. V., Flavián, C., & Schepers, J. (2021). Service robot implementation: A theoretical framework and research agenda. *The Service Industries Journal*, 41(3–4), 203–225. <https://doi.org/10.1080/02642069.2019.1672666>
- Belanche, D., Casaló, L. V., Schepers, J., & Flavián, C. (2022). How do customers cope with service robots? A dual appraisal perspective. *Journal of Service Management*, 33(2), 164–190. <https://doi.org/10.1108/JOSM-08-2020-0263>
- Bruhn, M., Schoenmüller, V., Schäfer, D., & Heinrich, D. (2012). Brand authenticity: Towards a deeper understanding of its conceptualization and measurement. *Advances in Consumer Research*, 40, 567–576.
- Cheng, X., Zhang, X., Cohen, J., & Mou, J. (2022). Human vs. AI: Understanding the impact of anthropomorphism on consumer response to chatbots from the perspective of trust and relationship norms. *Information Processing & Management*, 59(3), 102940. <https://doi.org/10.1016/j.ipm.2022.102940>
- Davenport, T., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, 48(1), 24–42. <https://doi.org/10.1007/s11747-019-00696-0>
- Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3), 319–340. <https://doi.org/10.2307/249008>
- De Bruyn, A., Viswanathan, V., Beh, Y. S., Brock, J. K. U., & von Wangenheim, F. (2020). Artificial intelligence and marketing: Pitfalls and opportunities. *Journal of Interactive Marketing*, 51, 91–105. <https://doi.org/10.1016/j.intmar.2020.04.007>
- Faul, F., Erdfelder, E., Lang, A. G., & Buchner, A. (2007). G*Power 3: A flexible statistical power analysis program for the social, behavioral, and biomedical sciences. *Behavior Research Methods*, 39(2), 175–191. <https://doi.org/10.3758/BF03193146>
- Fornell, C., & Larcker, D. F. (1981). Evaluating structural equation models with unobservable variables and measurement error. *Journal of Marketing Research*, 18(1), 39–50. <https://doi.org/10.1177/002224378101800104>
- Grand View Research. (2024). Generative AI in marketing market size, share & trends analysis report by application, by deployment, by region, and segment forecasts, 2024–2030. Grand View Research.



- Hair, J. F., Henseler, J., Dijkstra, T. K., & Sarstedt, M. (2014). Common beliefs and reality about partial least squares: Comments on Rönkkö and Evermann (2013). *Organizational Research Methods*, 17(2), 182–209. <https://doi.org/10.1177/1094428114526928>
- Hair, J. F., Risher, J. J., Sarstedt, M., & Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. *European Business Review*, 31(1), 2–24. <https://doi.org/10.1108/EBR-11-2018-0203>
- Hair, J. F., Sarstedt, M., & Ringle, C. M. (2022). Explaining and predicting open-ended constructs with PLS-SEM: Illustrations and guidelines for IS research. *Journal of the Association for Information Systems*, 23(6), 1551–1582. <https://doi.org/10.17705/1jais.00781>
- Hargittai, E. (2005). Survey measures of web-oriented digital literacy. *Social Science Computer Review*, 23(3), 371–379. <https://doi.org/10.1177/0894439305275911>
- Hartmann, J., Heitmann, M., Siebert, C., & Schamp, C. (2023). More than a feeling: Accuracy and application of sentiment analysis. *International Journal of Research in Marketing*, 40(1), 75–87. <https://doi.org/10.1016/j.ijresmar.2022.05.005>
- Henseler, J., Ringle, C. M., & Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43(1), 115–135. <https://doi.org/10.1007/s11747-014-0403-8>
- Huang, M. H., & Rust, R. T. (2021). A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science*, 49(1), 30–50. <https://doi.org/10.1007/s11747-020-00749-9>
- Huang, M. H., & Rust, R. T. (2022). A framework for collaborative artificial intelligence in marketing. *Journal of Retailing*, 98(2), 209–223. <https://doi.org/10.1016/j.jretai.2021.03.001>
- Jakesch, M., Hancock, J. T., & Naaman, M. (2023). Human heuristics for AI-generated language are flawed. *Proceedings of the National Academy of Sciences*, 120(11), e2208839120. <https://doi.org/10.1073/pnas.2208839120>
- Kim, J., & Park, J. (2023). Disclosure of AI-generated content and consumer trust in digital marketing: The moderating role of message framing. *Computers in Human Behavior*, 147, 107857. <https://doi.org/10.1016/j.chb.2023.107857>
- Kietzmann, J., Paschen, J., & Treen, E. (2018). Artificial intelligence in advertising: How marketers can leverage artificial intelligence along the consumer journey. *Journal of Advertising Research*, 58(3), 263–267. <https://doi.org/10.2501/JAR-2018-035>
- Longoni, C., Fradkin, A., Cian, L., & Pennycook, G. (2022). News from generative artificial intelligence is believed less. *Proceedings of the 2022 ACM CHI Conference on Human*



Factors in Computing Systems (CHI '22), 1–15.
<https://doi.org/10.1145/3491102.3502045>

- Luo, X., Tong, S., Fang, Z., & Qu, Z. (2019). Frontiers: Machines vs. humans: The impact of artificial intelligence chatbot disclosure on customer purchases. *Marketing Science*, 38(6), 937–947. <https://doi.org/10.1287/mksc.2019.1192>
- Matz, S. C., Teeny, J. D., Vaid, S. S., Peters, H., Harari, G. M., & Cerf, M. (2024). The potential of generative AI for personalized persuasion at scale. *Scientific Reports*, 14, 4692. <https://doi.org/10.1038/s41598-024-53755-0>
- McKinsey & Company. (2024). The state of AI in 2024: GenAI adoption reaches mainstream. McKinsey Global Institute.
- McKnight, D. H., & Chervany, N. L. (2001). What trust means in e-commerce customer relationships: An interdisciplinary conceptual typology. *International Journal of Electronic Commerce*, 6(2), 35–59. <https://doi.org/10.1080/10864415.2001.11044235>
- Moulard, J. G., Runnalls, C. P., & Folse, J. A. G. (2021). Brand authenticity: Testing the antecedents and outcomes of brand management's passion for their brands. *Journal of Brand Management*, 28(6), 660–675. <https://doi.org/10.1057/s41262-021-00247-3>
- Napoli, J., Dickinson, S. J., Beverland, M. B., & Farrelly, F. (2014). Measuring consumer-based brand authenticity. *Journal of Business Research*, 67(6), 1090–1098. <https://doi.org/10.1016/j.jbusres.2013.06.001>
- Peer, E., Rothschild, D., Gordon, A., Evernden, Z., & Damer, E. (2022). Data quality of platforms and panels for online behavioral research. *Behavior Research Methods*, 54(4), 1643–1662. <https://doi.org/10.3758/s13428-021-01694-3>
- Pitardi, V., & Marriott, H. R. (2021). Alexa, she's not human but... Unveiling the drivers of consumers' trust in voice-based artificial intelligence. *Psychology & Marketing*, 38(4), 626–642. <https://doi.org/10.1002/mar.21457>
- Puntoni, S., Reczek, R. W., Giesler, M., & Botti, S. (2021). Consumers and artificial intelligence: An experiential perspective. *Journal of Marketing*, 85(1), 131–151. <https://doi.org/10.1177/0022242920953847>
- Reber, R., Schwarz, N., & Winkielman, P. (2004). Processing fluency and aesthetic pleasure: Is beauty in the perceiver's processing experience? *Personality and Social Psychology Review*, 8(4), 364–382. https://doi.org/10.1207/s15327957pspr0804_3
- Ringle, C. M., Wende, S., & Becker, J. M. (2022). SmartPLS 4. SmartPLS GmbH. <https://www.smartpls.com>
- Rust, R. T., & Huang, M. H. (2021). The feeling economy: How artificial intelligence is creating the era of empathy. Palgrave Macmillan. <https://doi.org/10.1007/978-3-030-52977-2>



- Schepman, A., & Rodway, P. (2023). The General Attitudes towards Artificial Intelligence Scale (GAAIS): Confirmatory validation and associations with personality, corporate distrust, and general trust. *International Journal of Human–Computer Interaction*, 39(13), 2724–2741. <https://doi.org/10.1080/10447318.2022.2085400>
- Sundar, S. S., & Kim, J. (2019). Interactivity and persuasion: Influencing attitudes with information and involvement. *Journal of Interactive Advertising*, 5(2), 5–18. <https://doi.org/10.1080/15252019.2005.10722099>
- Sundar, S. S., & Kim, J. (2022). Machine heuristic: How chatbots trigger the 'computer as social actor' paradigm and affect outcomes. In *Handbook of computer-mediated communication* (pp. 241–263). De Gruyter.
- Tene, O., & Polonetsky, J. (2022). Taming the golem: Challenges of ethical algorithmic decision-making. *North Carolina Journal of Law & Technology*, 19(1), 125–173.
- Venkatesh, V., & Morris, M. G. (2000). Why don't men ever stop to ask for directions? Gender, social influence, and their role in technology acceptance and usage behavior. *MIS Quarterly*, 24(1), 115–139. <https://doi.org/10.2307/3250981>
- Woebot Health. (2023). Annual impact report: AI-mediated therapeutic interactions and user trust dynamics. Woebot Health Research Division.
- Xiao, B., & Benbasat, I. (2022). Designing warning messages for detecting biased online product recommendations: An empirical investigation. *Information Systems Research*, 33(3), 832–850. <https://doi.org/10.1287/isre.2021.1084>
- Zhu, Z., Nakata, C., Sivakumar, K., & Grewal, D. (2022). Dynamic service design: How AI-enabled interaction adapts to customer feedback. *Journal of Marketing Research*, 60(2), 381–403. <https://doi.org/10.1177/00222437221124065>
- Złotowski, J., Proudfoot, D., Yogeewaran, K., & Bartneck, C. (2023). Anthropomorphism: Opportunities and challenges in human-robot interaction. *International Journal of Social Robotics*, 7(3), 347–360. <https://doi.org/10.1007/s12369-014-0267-6>

Conflicto de intereses:

Los autores declaran que no existe conflicto de interés posible.

Financiamiento:

No existió asistencia financiera de partes externas al presente artículo.

Agradecimiento:

N/A

Nota:

El artículo no es producto de una publicación anterior.