

Aceptación de la Inteligencia Artificial Generativa en la industria creativa: el rol del modelo UTAUT, reconocimiento y la confianza de marca en su adopción

Acceptance of Generative AI in the creative industry: the role of UTAUT, brand recognition and trust in adoption

Dominika Weglarz

Candidata a doctora en la Universidad Oberta de Catalunya, España
dweglarz@uoc.edu
<https://orcid.org/0009-0000-0248-676X>

Cintia Pla-Garcia

Profesora e investigadora en la Universidad Oberta de Catalunya, España
cplag@uoc.edu
<https://orcid.org/0000-0001-7276-6257>

Ana Isabel Jiménez-Zarco

Profesora e investigadora en la Universidad Oberta de Catalunya, España
ajimenez@uoc.edu
<https://orcid.org/0000-0002-8980-6814>

Recibido: 04/01/25 **Revisado:** 27/01/25 **Aprobado:** 17/02/25 **Publicado:** 01/04/25

Resumen: el estudio explora los factores que influyen en la adopción de la inteligencia artificial (IA) generativa en la industria creativa, tomando como referencia la Teoría Unificada de Aceptación y Uso de Tecnología (UTAUT), y la teoría del capital de marca. Numerosos estudios han demostrado la capacidad explicativa del modelo UTAUT en la adopción tecnológica en diferentes sectores; sin embargo, no se había analizado cómo el capital de marca, especialmente el conocimiento y la confianza influye a la adopción de la Inteligencia Artificial Generativa. El capital de la marca es especialmente relevante en la industria creativa, donde el bajo conocimiento tecnológico hace que la marca de IA sea una fuente clave de información e influencia en la toma de decisiones. Una muestra de 208 profesionales creativos de EE. UU. y España validó el modelo propuesto utilizando PLS-SEM. Los resultados indican que la expectativa de rendimiento, las condiciones facilitadoras y la confianza en la marca influyen positivamente en la intención de uso de la IA Generativa, mientras que el reconocimiento de marca tiene un efecto negativo. La influencia social y la expectativa de esfuerzo no presentaron resultados estadísticamente significativos. El modelo explica el 67 % de la varianza en la intención de uso ($R^2 = 0.679$), indicando un alto poder predictivo. Se destaca la importancia del desempeño, soportes accesibles y confianza en la marca, abordando los desafíos de la percepción y reconocimiento de marca.

Palabras clave: Inteligencia Artificial Generativa, UTAUT, reconocimiento, confianza, industrias creativas, Adobe, capital de marca, adopción de tecnología.

Cómo citar: Weglarz, D., Pla-Garcia, C. y Jiménez-Zarco, A. I. (2025). Aceptación de la Inteligencia Artificial Generativa en la industria creativa: el rol del modelo UTAUT, reconocimiento y la confianza de marca en su adopción. *Retos Revista de Ciencias de la Administración y Economía*, 15(29), pp. 9-27. <https://doi.org/10.17163/ret.n29.2025.01>

Abstract: this study explores the factors influencing the adoption of Generative AI in the creative industry, focusing on the Unified Theory of Acceptance and Use of Technology (UTAUT) factors: performance expectancy, effort expectancy, facilitating conditions, social influence, and consumer-based brand equity factors: brand recognition and brand trust. While previous research has emphasized the importance of UTAUT constructs in technology adoption, the influence of brand equity factors remains underexplored. This study bridges this gap and provides insights to enhance adoption strategies. Standardized questionnaires were used, incorporating UTAUT constructs and brand-related variables such as Brand Recognition and Brand Trust. A sample of 208 creative professionals from the US and Spain validated the proposed model using PLS-SEM. Results reveal that performance expectancy, facilitating conditions, and brand trust positively influence the behavioral intention to use Generative AI tools, while brand recognition negatively influences behavioral intention. Social influence and effort expectancy did not present statistically significant results. The model explains 67 % of the variance in behavioral intention ($R^2 = 0.679$), indicating strong predictive power. These insights contribute to developing effective adoption strategies for Generative AI in the creative industry.

Keywords: Generative artificial intelligence, UTAUT, recognition, trust, creative industries, Adobe, brand equity, technology adoption.

Introducción

En la actualidad, la industria creativa se caracteriza por los rápidos cambios que se han producido a raíz de la revolución digital. La creciente interacción del sector creativo con las tecnologías ha dado lugar a nuevas formas de expresión artística (Abbasi *et al.*, 2017). A través de la Inteligencia Artificial Generativa (Gen IA) estamos experimentando avances transformadores, permitiendo niveles sin precedentes de eficiencia y creatividad. Por lo tanto, se necesita comprender los criterios de adopción entre los profesionales para el éxito de esta innovación, especialmente en aquellas industrias que la utilizan en su día a día. El sector

creativo se basa en la originalidad y la producción de ideas imaginativas, que requieren la participación humana. Gen IA se está utilizando en flujos de trabajo creativos, ofreciendo beneficios potenciales en la productividad y la eficiencia de tiempo (Vinchon *et al.*, 2023). El creciente rol de la IA ha impulsado una agenda de investigación para explorar su impacto en la fuerza de trabajo creativa. Aunque somos testigos del crecimiento de la generación IA en 2024, una de las primeras tomas en el despliegue de IA en el sector creativo tuvo lugar en 2016. Se creó el Next Rembrandt, y se produjo la pintura impresa tridimensional solamente basada en datos de entrenamiento de la cartera de Rembrandt.

Figura 1

El Next Rembrandt




Nota. Wunderman Thompson, 2016.

La adopción de la IA ha aumentado exponencialmente desde el lanzamiento del Next Rembrandt. Esto se demuestra al usar el arte de la IA como una nueva disciplina. Con el auge de las artes generadas por la Generación de Inteligencia Artificial, las galerías y los curadores se están adaptando rápidamente. Por ejemplo, The UnReal Exhibition, parte de NSDM Fuse en Ámsterdam muestra una amplia variedad de arte realizada en IA y de escritores artistas, explorando los límites de la creatividad y la última tecnología. En diciembre de 2023 se inauguró en Nueva York otra galería de arte de Gen IA. Artechouse- World of AI-Imagination es una exposición de arte que combina la creatividad humana y los gráficos computacionales de IA de vanguardia (Artechouse, 2023). La exposi-

ción Artechouse está construida sobre la base del hardware NVIDIA y su herramienta generativa de IA. Estas exposiciones son una forma de mostrar el potencial de la IA en la industria creativa y dominar sus capacidades, porque la IA se está convirtiendo en una parte integral del proceso artístico (Smith, 2022). Cumplen los deseos de nuevas formas de arte, a la par que proporcionan una discusión reflexiva sobre la producción de arte y el significado de la creatividad, brindando una nueva percepción de utilizar la generación de inteligencia artificial como una herramienta creativa en la era del arte digital (Smith, 2022). La comunidad creativa adopta la IA general de muchas maneras, desde la creación de contenido hasta la racionalización de las tareas.

Figura 2


Ejemplos de exposiciones de arte de IA



Nota. Smith, 2022.

Figura 3

Artechouse-World of AI-Imagination, Nueva York, 2023



A medida que los profesionales de las industrias creativas aprovechan la IA de Gen para agilizar las tareas y mejorar su trabajo, su uso va en aumento (Sánchez, 2023). La investigación sugiere que Gen IA podría automatizar hasta el 26 % de las funciones en los sectores de artes, diseño, entretenimiento, medios y deportes (Hatzius *et al.*, 2023). De igual manera, otros hallazgos indican que el 75 % de los profesionales creativos consideran a la IA de Generación útil para tareas como la edición de imágenes y la búsqueda, enfatizando su papel como facilitador más que como creador (Anantrasirichai y Bull, 2022). Desde el lanzamiento de ChatGPT, Gen IA ha permitido la creación de contenido original utilizando mensajes de lenguaje natural y ha ganado rápido protagonismo debido a sus interfaces fáciles de usar (Chui, 2023; Anantrasirichai y Bull, 2020).


Sin embargo, surgen preocupaciones éticas en medio de la creciente adopción. Estas tienen sus raíces en la originalidad, la autoría y el potencial para el desplazamiento laboral. A medida que los sistemas de IA producen cada vez más trabajos creativos, surgen preguntas con respecto a la propiedad y pueden conducir a dilemas éticos y al rechazo de la tecnología (Chen, 2024; Caporusso, 2023). Por lo que se necesita abordar estas preocupaciones para fomentar la adopción.

El modelo de Teoría Unificada de Aceptación y Uso de la Tecnología (UTAUT) se ha convertido en un marco útil para comprender y predecir la adopción de esta tecnología (Yin *et al.*, 2023, Menon y Shilpa, 2023, Cabrera-Sánchez, 2021). El modelo UTAUT integra ocho teorías fundamentales, incluyendo el Modelo de Aceptación de Tecnología (TAM), la Teoría de Acción Razonada (TRA) y la Teoría de Difusión de Innovación (IDT). UTAUT considera cuatro factores clave; expectativa de desempeño (PE), expectativa de esfuerzo (EE), influencia social (SI) y condiciones facilitadoras (FC) (Venkatesh *et al.*, 2003).

Según este modelo, la PE = expectativa de desempeño representa las percepciones de los individuos sobre los beneficios y la utilidad que esperan obtener del uso de la nueva tecnología; expectativa de esfuerzo (EE) se define como el grado de facilidad asociado con el uso de la nueva tecnología; SI= influencia social es el grado en que un individuo percibe que otros importantes creen que debería utilizar la última tecnología; y condiciones facilitadoras (FC) es el grado en que un individuo cree que existe infraestructura tecnológica para apoyar el uso de la nueva tecnología (Venkatesh *et al.*, 2003). En la figura 4 se presenta el modelo UTAUT original.

Figura 4

Modelo de la teoría unificada de la aceptación y uso de la tecnología



Nota. Venkatesh *et al.*, 2003.

UTAUT se ha utilizado para examinar la adopción de la IA en varias industrias, como la salud y la seguridad (De Almeida *et al.*, 2023), los servicios financieros (Jiang *et al.*, 2024) y, por último, las industrias creativas (Yin *et al.*, 2023, Menon y Shilpa, 2023). Los resultados resaltan la expectativa de desempeño, la expectativa de esfuerzo y la influencia social como predictores significativos del uso de la IA general, sin un impacto importante de condiciones facilitadoras (Yin *et al.*, 2023; Menon y Shilpa, 2023; Cabrera-Sánchez, 2021). A pesar de sus beneficios, las limitaciones de esta tecnología, como la falta de autenticidad y de contacto personal, siguen siendo motivo de preocupación para los usuarios de la industria creativa (Wang *et al.*, 2023).

Sin embargo, la mayoría de los profesionales creativos ven a la IA como una herramienta para complementar sus habilidades en lugar de reemplazarlas, subrayando la importancia de fomentar el entendimiento y la aceptación (Yin *et al.*, 2023). Yin *et al.* (2023) aplicaron el modelo UTAUT2, incorporando motivación hedónica, valor de precio y hábito, mientras que Zhang (2020) se centró en la música, examinando factores como la expectativa de rendimiento, la expectativa de esfuerzo, la influencia social, la innovación individual y el valor percibido. En particular, Zhang encontró que la innovación percibida tuvo el mayor impacto en la adopción de la música por IA, seguida por la expectativa de rendimiento y la expectativa de esfuerzo. Sin embargo, estos hallazgos están limitados geográficamente y no proporcionan ideas universales. La industria creativa en las culturas occidentales puede demostrar patrones distintos influenciados por el individualismo, la autonomía creativa y las actitudes diferentes hacia las tecnologías emergentes (Cabrera-Sánchez, 2021).

Como se indicó en la investigación anterior, la intención conductual, que determina la aceptación del uso de IA, puede atribuirse fuertemente a la expectativa de desempeño (Maican *et al.*, 2023, Menon y Shilpa, 2023, Cabrera-Sánchez, 2021), la expectativa de esfuerzo (Zhang, 2020, Menon, Shilpa, 2023), la condición facilitadora (Menon y Shilpa, 2023), y la influencia social (Maican *et al.*, 2023, Menon y Shilpa, 2023). La investigación mostró que el impacto de la expectativa de

esfuerzo es más notable en casos de baja creatividad (Maican *et al.*, 2023). Si bien estos estudios mejoran el marco UTAUT incorporando variables como la confianza de los usuarios y las respuestas emocionales, pasan por alto factores adicionales que podrían apoyar a los usuarios en industrias caracterizadas por una experiencia tecnológica limitada.

Las industrias creativas a menudo carecen de un buen conocimiento de la innovación, diferentes niveles de madurez y falta de habilidades, lo que presenta una barrera para el rápido uso de la tecnología (Abbasi *et al.*, 2017). Esta brecha requiere depender de diferentes maneras de asegurar la calidad. En industrias con conocimientos tecnológicos limitados, la equidad de marca basada en el consumidor es un sustituto de la evaluación directa de la calidad. La confianza que proporcionan los factores de marca apoya la toma de decisiones y reduce la incertidumbre (Abbasi *et al.*, 2017). El reconocimiento y la confianza de la marca son componentes esenciales de la equidad de la marca basada en el consumidor, que modela el comportamiento del consumidor a lo largo del recorrido del consumidor. El reconocimiento de marca se refiere a la capacidad de los consumidores para recordar o identificar una marca dentro de una categoría de producto y progresa en tres etapas: reconocimiento (conciencia asistida), recuerdo (conciencia no asistida) y parte superior de la mente (opción preferida) (Kathuria *et al.* 2018). El fuerte reconocimiento de la marca es crucial en las primeras etapas del viaje del consumidor, donde garantiza la inclusión de la marca en los conjuntos de consideración durante las fases de reconocimiento de la necesidad, búsqueda de información y evaluación (García y Yábar, 2023). El alto reconocimiento facilita la toma de decisiones, fomenta la lealtad y aumenta las intenciones de compra (Izza *et al.*, 2024; Rubio *et al.*, 2014). La confianza en la marca se basa en el reconocimiento, lo que representa la confianza en la capacidad de una marca para cumplir sus promesas y cumplir sus expectativas (García y Yábar, 2023). La confianza modera la percepción del riesgo, promueve el compromiso del cliente y profundiza las conexiones emocionales con una marca (Hess y Story, 2005). La confianza es necesaria en las industrias basadas en servi-

cios, donde las evaluaciones emocionales y las repetidas interacciones positivas impulsan las relaciones a largo plazo (Bowden, 2014). Tanto el reconocimiento como la confianza impactan en el uso de la marca. El reconocimiento simplifica las decisiones, creando familiaridad y asociaciones positivas (Rios y Riquelme, 2010). La confianza refuerza la lealtad alineando los valores de marca con los valores de los consumidores, fomentando el compromiso y reduciendo los riesgos percibidos (Roets *et al.*, 2014).

Este estudio busca abordar la brecha de investigación mediante la investigación del papel de los factores relacionados con la marca en la configuración de la aceptación de la generación IA entre los individuos en las industrias creativas, para mejorar la garantía de calidad en sectores con conocimientos tecnológicos limitados. Esta investigación se basa en el modelo UTAUT porque su validez ha sido comprobada en entornos profesionales y empresariales (Chatterjee *et al.*, 2021; Zhang, 2020). Su objetivo es abordar esta brecha explorando cómo los factores de equidad de marca interactúan con los constructos UTAUT establecidos para dar forma al comportamiento del usuario y ayudar a los profesionales creativos a adaptar la IA de generación de forma efectiva.

Materiales y métodos

Modelo teórico e hipótesis

Con base en las preguntas de investigación se establecieron los siguientes modelos teóricos e hipótesis para el estudio:

Expectativa de rendimiento

La expectativa de rendimiento es el grado en el que un individuo que trabaja en la industria creativa cree que las herramientas de texto a imagen de la generación de inteligencia artificial le ayudarán a obtener mejoras en el rendimiento laboral. Las herramientas de IA general pueden afectar significativamente a los flujos de trabajo al automatizar tareas repetitivas y permitir la creación de contenido o ideación. Estudios previos mostraron que la expectativa de desempeño pre-

dice significativamente la intención conductual de usar IA (Maican *et al.*, 2023; Menon y Shilpa, 2023; Cabrera-Sánchez, 2021). Las personas esperan que el uso de la tecnología de IA mejore su rendimiento laboral (Yin *et al.*, 2023). Por lo tanto, la hipótesis se estructura de la siguiente manera:

H1: La expectativa de rendimiento influye positivamente en el aumento de la intención del uso de las herramientas de Inteligencia Artificial Generativa de imágenes a partir de texto.

Expectativa de esfuerzo

La expectativa de esfuerzo es el grado de facilidad asociado con el uso de herramientas de texto a imagen de Gen IA por parte de individuos que trabajan en la industria creativa. Las herramientas de IA general, aunque pueden mejorar la eficacia del trabajo, requieren interfaces fáciles de usar y un uso intuitivo para lograr la adaptación entre los nuevos usuarios. Estudios previos confirman que la expectativa de esfuerzo impacta positivamente en la intención conductual, especialmente en campos donde interfaces complejas o no intuitivas pueden disuadir el uso regular (Chuyen y Vinh, 2023). Creemos que los profesionales de la industria creativa prefieren herramientas con un esfuerzo educativo minimizado (Bravo *et al.*, 2020). La facilidad de uso de una nueva herramienta reduce las barreras a la adopción, haciendo de la expectativa de esfuerzo un importante predictor en sectores dinámicos, como la industria creativa (Zhang, 2020; Menon y Shilpa, 2023). Por lo tanto, la hipótesis se estructura de la siguiente manera:

H2: La expectativa de esfuerzo influye positivamente en el aumento de la intención del uso de las herramientas de Inteligencia Artificial Generativa de imágenes a partir de texto.

Influencia social

La influencia social es el grado en que un individuo que trabaja en la industria creativa percibe que la gente importante cree que él o ella debe usar las herramientas de texto a imagen de la Generación IA. Los profesionales creativos pueden confiar en las opiniones externas de los clientes, compañeros de trabajo o líderes de la industria. Los estudios sobre la adopción de IA en la industria del diseño demostraron que es probable que los individuos adopten dichas tecnologías si perciben que sus pares o líderes influyentes respaldan su uso (Chuyen y Vinh, 2023). Además, otros estudios encontraron que los profesionales de la industria musical a menudo adoptan herramientas de IA basadas en tendencias a nivel industrial, reflejando el impacto de la influencia social en la adopción de IA (Maican *et al.*, 2023). Por lo tanto, la hipótesis se estructura de la siguiente manera:

H3: La influencia social influye positivamente en el incremento la intención del uso de las herramientas de Inteligencia Artificial Generativa de imágenes a partir de texto.

Condición facilitadora

La condición facilitadora es el grado en que una persona que trabaja en la industria creativa cree que la infraestructura técnica de la organización existe para apoyar el uso de herramientas de texto a imagen de la generación de inteligencia artificial, y comprende el apoyo organizativo, de capacitación y técnico disponible para el usuario. Se ha demostrado que la condición facilitadora mejora las estrategias que promueven la aceptación de Gen IA (Menon y Shilpa, 2023). La disponibilidad de un entrenamiento y aprendizaje robusto impacta positivamente en la confianza del usuario, lo que indica que facilitar la condición es un predictor de uso de la Gen IA (Chuyen, Vinh, 2023). Por lo tanto, la hipótesis se estructura de la siguiente manera:

H4: Facilitar la condición influye positivamente en el aumento de la intención del uso de las herramientas de Inteligencia Artificial Generativa de imágenes a partir de texto.

Reconocimiento de marca

El reconocimiento de marca es la capacidad de las personas que trabajan en la industria creativa de recordar la marca en una categoría de servicios de texto a imagen de la generación de inteligencia artificial. El reconocimiento de marca es el primer paso en el camino del consumidor y la decisión de empezar a usar un producto (Sasmita y Suki, 2015). Además, los consumidores prefieren utilizar solo marcas reconocidas con un buen historial de rendimiento (Kathuria *et al.*, 2018). Por lo tanto, la hipótesis se estructura de la siguiente manera:


H5: Cuanto más reconocida la marca de la Inteligencia Artificial Generativa de imágenes a partir de texto, mas influencia positiva en la intención de uso tiene.

Confianza en la marca

La confianza en la marca es la confianza que las personas que trabajan en la industria creativa tienen en la capacidad de la marca para cumplir sus promesas. En estudios anteriores vimos que la confianza en la capacidad de la herramienta de IA para proporcionar el mejor rendimiento de la tarea y la confianza en el cumplimiento de la promesa de servicio son predictores de la adopción de IA (Cabrera-Sánchez, 2021). Además, la satisfacción y la calidad del servicio impactan positivamente en la adopción del servicio de IA (Chatterjee *et al.*, 2021). Por lo tanto, la hipótesis se estructura de la siguiente manera:

H6: Cuanto más confiable la marca de la Inteligencia Artificial Generativa de imágenes a partir de texto, mas influencia positiva en la intención de uso tiene.

Nuestro modelo teórico se presenta en la figura 5:

Figura 5*Modelo teórico e hipótesis*

Recopilación de datos

Las hipótesis se validaron utilizando el cuestionario estandarizado Qualtrics, adoptando los ítems sugeridos por Venkatesh *et al.* (2012) en aceptación y uso de la tecnología de la información por parte del consumidor: ampliar la teoría unificada de aceptación y uso de la tecnología. Además, se introdujeron dos variables relacionadas con la marca: reconocimiento de marca y confianza de marca, adoptando elementos sugeridos por Wang *et al.* (2008), en “Global brand equity model: combinar enfoques basados en el cliente con enfoques de resultados del mercado de productos”.

La plataforma de texto a imagen de Adobe Firefly se especificó como el tema para las variables de equidad de marca basadas en el consumidor.

El cuestionario constaba de dos secciones: Sociodemográficos (género, edad, lugar de residencia, perfil creativo-ocupacional, experiencia con la Generación IA) y factores que influyen en la intención de uso; ítems seleccionados para constructos de expectativa de rendimiento, expectativa de esfuerzo, influencia social, condiciones facilitadoras, reconocimiento de marca, confianza de marca.

Cada constructo constaba de cinco ítems, adaptados de las escalas originales mencionadas anteriormente. No se realizó ninguna prueba previa, ya que estos ítems han sido ampliamente utilizados y adaptados por otros investigadores. Los encuestados evaluaron cada variable utilizando una escala Likert de 7 puntos (1: “Totalmente en desacuerdo” a 7: “Totalmente de acuerdo”). El estudio se centró en una muestra de personas

que trabajan en la industria creativa en Estados Unidos y España. El cuestionario se distribuyó a través de comunidades creativas en línea utilizando un enlace de encuesta. La muestra fue extraída al azar de un colectivo creativo de profesionales en publicidad, marketing y otras industrias creativas. Esta selección aleatoria tuvo como objetivo minimizar el sesgo y mejorar la generalización de los resultados. Después de las condiciones de Westland (2010) y Soper (2024) para realizar PLS-SEM se recogieron un total de 224 respuestas y 208 fueron respuestas completas y válidas. Este número de respuestas nos proporciona un tamaño de muestra superior al mínimo requerido para

la estructura del modelo y el margen de error es inferior al 5 % deseado.

Resultados y discusión

Análisis de datos

En primer lugar, se analizaron las estadísticas descriptivas de la muestra. La muestra total de 224 presenta las siguientes características en la tabla 1. De la muestra total, 208 fueron respuestas válidas que sirven de base para el análisis del modelo de medición.

Tabla 1

Descripción de la muestra

	Muestra	%
Edad		
Menos de 35	103	46
Mayor de 35	121	54
Género		
Femenino	93	41,5
Masculino	130	58
Prefiero no decir	1	0,5
Lugar de residencia		
España	104	46,5
USA	104	46,5
Otros	16	7
Experiencia con Gen IA		
Sí	138	62
No	86	38
Experiencia con Gen IA Texto a imagen		
Sí	88	39
No	136	61

Para validar el modelo propuesto, los datos se sometieron a análisis mediante el método de mínimos cuadrados parciales (PLS), que permite el análisis de relaciones complejas entre variables

y las pone en práctica (Hair *et al.*, 2017). Los datos se analizaron con el software SmartPLS 4.0. El análisis de los datos se estructuró en dos fases

clave: la evaluación del modelo de medición y el análisis del modelo estructural.


En la primera fase, se evaluó la fiabilidad y validez del modelo de medición, calculando el alfa de Cronbach (α), la fiabilidad compuesta (CR) y la varianza media extraída (AVE). Se examinaron las cargas factoriales (λ) para determinar la fiabilidad individual del ítem, y se evaluó la validez discriminante utilizando el criterio de Fornell-Larcker, asegurando que la raíz cuadrada del AVE de un constructo supera sus correlaciones con otros constructos (Hair *et al.*, 2017). Adicionalmente, se analizó la validez individual de la condición formativa facilitadora de constructos. Se realizó una revisión exhaustiva de la literatura para asegurar la validez de la condición facilitadora como un constructo formativo. Los estudios que aplican UTAUT en áreas como la educación, la banca móvil y las bibliotecas digitales destacan sistemáticamente que la condición facilitadora refleja factores habilitantes distintos (por ejemplo, apoyo técnico y organizativo), lo que justifica una especificación formativa (Sanmukhiya, 2020, Handayani, 2023). El valor de la validez convergente en el estudio de Sanmukhiya confirma que las condiciones facilitadoras se miden efectivamente como un constructo formativo (Sanmukhiya, 2020). Se evaluó la multicolinealidad utilizando el Factor de Inflación de Varianza (VIF), con valores

por debajo del umbral recomendado de 3 (Hair *et al.*, 2019). Luego se evaluaron los pesos exteriores y las cargas para medir la contribución de cada indicador al constructo latente. Finalmente, la validez discriminante se verificó utilizando la ratio HTMT. En la segunda fase, se analizó el modelo estructural utilizando la técnica de *bootstrap-trapping* para probar las hipótesis propuestas. Esto incluyó estimar la significancia de las relaciones variables a través de las estadísticas *t*, los valores *p* y los coeficientes de ruta (β), lo que llevó a las conclusiones del estudio.

Evaluación del modelo de medición

En primer lugar, se evaluó la validez de todos los elementos individuales del modelo original. Las cargas externas deberían ser idealmente de 0,708 o más (Bagozzi y Yi, 1988; Hair *et al.*, 2019). Esto indica que el indicador explica al menos el 50 % de la varianza en el constructo (desde $0,708^2 \approx 0,50$). Utilizamos el modelo teórico para validar el modelo de medición a través de PLS-SEM, centrándonos en evaluar todas las variables latentes para su fiabilidad y validez. Una vez validado, ajustamos nuestro modelo de medición mostrado en la figura 6.

Figura 6
Modelo de medición



Como se muestra en la tabla 2, se determinó la validez de los distintos elementos. Todas las cargas externas para constructos reflectantes PE, EE, SI, BR, BT y BI están muy por encima de 0,708, lo que sugiere niveles suficientes de confiabilidad del indicador. Solo las cargas externas para FC no cumplen los criterios, porque es un constructo formativo. La fiabilidad del compuesto, que indica la consistencia interna, se consideró aceptable con

todas las cargas de construcción que superan el umbral de 0,7. La validez convergente, que asegura que los indicadores miden el mismo concepto, se evaluó usando el método AVE. Siguiendo los criterios de Fornell y Larcker de un valor mínimo de AVE de 0,5, todos los constructos superan este umbral, lo que indica que cada constructo explica al menos el 50 % de la varianza en sus indicadores, demostrada en la tabla 2.

Tabla 2

Información general sobre la fiabilidad y validez de constructos

		Carga externa	Alfa de Cronbach	Fiabilidad compuesta (rho_a)	Fiabilidad compuesta (rho_c)	AVE
PE	PE1	0,908	0,905	0,917	0,906	0,709
	PE2	0,842				
	PE3	0,900				
	PE5	0,877				
EE	EE3	0,899	0,775	0,776	0,775	0,633
	EE4	0,908				
SI	SI1	0,820	0,768	0,786	0,760	0,520
	SI4	0,827				
	SI5	0,824				
BR	BR2	0,863	0,919	0,933	0,917	0,738
	BR3	0,909				
	BR4	0,892				
	BR5	0,920				
BT	BT1	0,880	0,906	0,914	0,902	0,700
	BT3	0,874				
	BT4	0,873				
	BT5	0,902				
BI	BI1	0,909	0,872	0,876	0,874	0,698
	BI2	0,914				
	BI4	0,854				

Se realizó una prueba de validez discriminante utilizando el criterio de Fornell-Larcker y la relación heterotrait-Monotrait. La tabla 3 muestra los resultados, en particular, las correlaciones entre los constructos son inferiores a la raíz cuadrada del EAV, lo que indica que cada construc-

to comparte más varianza con sus indicadores que con cualquier otro constructo del modelo. En consecuencia, los seis constructos reflectivos presentan una fuerte consistencia interna y validez convergente.

Tabla 3

Validez discriminante- Criterio Fornell-Larcker y ratio Heterotrait-Monotrait (HTMT)

	Criterio de Fornell-Larcker					Ratio heterotrait-monotrait (HTMT)					
	PE	EE	SI	BR	BT	PE	EE	SI	BR	BT	BI
PE	0,842										
EE	0,637	0,795				0,639					
SI	0,711	0,517	0,721			0,713	0,515				
BR	0,324	0,340	0,474	0,859		0,332	0,332	0,494			
BT	0,337	0,287	0,512	0,809	0,837	0,347	0,285	0,532	0,827		
BI	0,892	0,613	0,679	0,290	0,384	0,890	0,612	0,669	0,288	0,382	

La evaluación del constructo formativo comenzó evaluando la multicolinealidad para la variable FC utilizando la FIV, con valores por debajo del umbral recomendado de 3 (Hair *et al.*, 2019), confirmando que no existen problemas críticos de multicolinealidad como se demuestra en la tabla 4. Luego se evaluaron los pesos y las car-

gas externas para medir la contribución de cada indicador al constructo latente. Mientras que 4 de 5 indicadores mostraron fuertes contribuciones (cargas > 0.5), la FC1 mostró baja contribución, pero se mantuvo por importancia conceptual. El *bootstrapping* confirmó que cuatro indicadores fueron estadísticamente significativos ($p < 0,05$).

Tabla 4

Evaluación de la multipolinealidad VIF

	VIF
FC1	1,022
FC2	1,314
FC3	1,280
FC4	1,223
FC5	1,127

Por último, se verificó la validez discriminante utilizando el ratio HTMT que se situó dentro de

los umbrales aceptables, validando el constructo como se muestra en la tabla 5.

Tabla 5*Ratio Heterotrait-Monotrait*

	01.PE	02.EE	03.SI	04.FC	05.BR	06.BT	08.BI
01.PE							
02.EE	0,639						
03.SI	0,713	0,515					
04.FC	0,577	0,620	0,509				
05.BR	0,332	0,332	0,494	0,333			
06.BT	0,347	0,285	0,532	0,377	0,827		
08.BI	0,890	0,612	0,669	0,608	0,288	0,382	

Evaluación del modelo estructural

El modelo se evaluó mediante la obtención de los coeficientes de trayectoria, valores de p, valores de T, coeficiente de determinación (R²) y relevancia predictiva (Q²). Los coeficientes de ruta de la expectativa de rendimiento y la intención del uso de las herramientas de la inteligencia artificial generativa (H1), la condición de facilitación y la intención del uso de las herramientas de la inteligencia artificial generativa (H4), el reconocimiento de marca y la intención del uso de las

herramienta de la inteligencia artificial generativa (H5), y la confianza de marca y la intención del uso de las herramientas de la inteligencia artificial generativa (H6) fueron 0,638, 0,137, -0,134, 0,147 con valores de p 0,01; 0,019 y 0,017, respectivamente. En la tabla 6 se presentan los coeficientes de trayectoria junto con sus correspondientes valores de p. Cuatro coeficientes de ruta son estadísticamente significativos de las seis relaciones hipotéticas, lo que respalda cuatro de las seis hipótesis propuestas.

Tabla 6*Coefficientes de trayectoria*

	Modelo R ² =0,679 (67%) Modelo Q ² = 0,649 (64%)		
	Coefficiente de ruta	Valores P	Soporte
H1: PE ->BI	0,638	0,000	H1 aceptado
H2.EE -> BI	0,057	0,139	H2 rechazado
H3 SI ->BI	0,084	0,088	H3 rechazado
H4 FC ->BI	0,137	0,010	H4 aceptado
H5. BR ->BI	-0,134	0,020	H5 parcialmente aceptado


H6.BT ->BI	0,147	0,017	H6 aceptado
------------	-------	-------	-------------

Como se indica en la tabla 6 (R^2), el modelo representa el 67 % de la varianza en la intención de comportamiento de usar servicios de texto a imagen de la generación de inteligencia artificial en industrias creativas, impulsado por los factores de esperanza de rendimiento, condición de facilitación, reconocimiento de marca y confianza de marca. La expectativa de rendimiento

se identifica como el predictor más fuerte (= 0,638, $p < 0,001$). De acuerdo con los umbrales establecidos para la varianza explicada, este efecto puede clasificarse como moderado, lo que sugiere que el modelo proporciona una explicación de la variación en las intenciones de los usuarios de adoptar la tecnología.

Figura 7

Modelo estructural final con coeficientes de trayectoria, valores p y cuadrado R



El valor Q^2 de 0,649 presentado en la tabla 6, indica que el modelo tiene una importancia predictiva sustancial para la Intención Conductual. Los valores de Q^2 mayor que cero sugieren que el modelo tiene poder predictivo, y un valor de 0,649 implica una fuerte capacidad del mode-

lo para predecir la BI en base a los predictores utilizados.

Discusión

El objetivo de este estudio fue identificar los principales factores que influyen en la adopción de las herramientas de texto a imagen de Gen IA en la industria creativa, ampliando el modelo UTAUT e incorporando el reconocimiento de marca y la confianza de la marca. Los hallazgos resaltan la expectativa de rendimiento como el predictor más fuerte de la intención del uso, en donde también se observa una influencia positiva en condiciones facilitadoras y confianza de la marca. Sin embargo, el reconocimiento de la marca tiene una influencia negativa en la intención del uso, debido a la identidad de marca establecida de Adobe en los servicios creativos tradicionales en conflicto con sus nuevas ofertas generativas de IA. La expectativa de esfuerzo y la influencia social no muestran ninguna influencia significativa, lo que resulta en cuatro de las seis hipótesis establecidas.

Los hallazgos se alinean con la literatura existente sobre el uso de tecnología, particularmente el poder predictivo de la expectativa de rendimiento (Maican *et al.*, 2023; Upadhyay *et al.*, 2022) lo que facilita la condición en la intención conductual (Anantrasirichai y Bull, 2020), y refuerza la expectativa de rendimiento como el predictor más fuerte de la intención de comportamiento para adoptar las herramientas de la Gen IA. Los profesionales creativos ven cada vez más valor en las herramientas de IA que mejoran la productividad y los flujos de trabajo, alineándose con investigaciones anteriores (Maican *et al.*, 2023; Menon y Shilpa, 2023). Para los profesionales de la industria creativa expectativa de rendimiento es el motor de adopción más significativo. Se necesita hacer énfasis en cómo las herramientas de Gen IA agilizan los flujos de trabajo, mejoran la eficiencia y mejoran la calidad de salida, en especial en entornos de alta presión. De igual forma, facilitar las condiciones, como la disponibilidad de recursos, el apoyo externo y la compatibilidad de hardware (Anantrasirichai y Bull, 2020), también tiene un impacto positivo en la adopción. Los sistemas y recursos de apoyo integral permiten a los creativos navegar la curva de aprendizaje, desarrollar nuevas habilidades y seguir siendo competitivos en una industria en rápida evolu-

ción. Las herramientas que ofrecen un soporte sólido y se alinean con los objetivos profesionales tienen más probabilidades de tener éxito.

Sin embargo, la expectativa de esfuerzo y la influencia social no mostraron un efecto significativo en la intención conductual, lo que contradice con las investigaciones anteriores donde se encontró que estos factores influyen positivamente en la intención conductual (Alhaiti, 2023; Maican *et al.*, 2023; Menon y Shilpa, 2023; Upadhyay *et al.*, 2022). Estudios anteriores confirman que la expectativa de esfuerzo tiene un impacto positivo en la intención conductual, especialmente en campos donde las interfaces complejas o no intuitivas pueden disuadir el uso regular (Chuyen y Vinh, 2023). Del mismo modo que con la influencia social, los estudios sobre la adopción de IA en la industria del diseño demostraron que los individuos son más propensos a adoptar estas tecnologías si perciben que sus pares o líderes influyentes respaldan su uso (Chuyen y Vinh, 2023). Además, otros estudios encontraron que los profesionales de la industria musical a menudo adoptan herramientas de IA basadas en las tendencias de toda la industria, reflejando el impacto de la influencia social en la adopción de IA (Maican *et al.*, 2023).

Cuando se trata de la equidad de marca basada en el consumidor, la IA ofrece garantía de calidad en industrias con conocimientos especializados limitados. La confianza que proporcionan los factores de marca apoya la toma de decisiones y reduce la incertidumbre (Abbasi *et al.*, 2017). La familiaridad con la marca aumenta la oportunidad de interactuar con sus ofertas de IA, especialmente cuando se habla de tecnologías nuevas y no renovadas (Cabrera-Sánchez *et al.*, 2021). Sin embargo, nuestros hallazgos sugieren una relación contraria dentro del contexto de las herramientas de texto a imagen de Adobe Gen IA. Los individuos familiarizados con Adobe como marca eran menos propensos a adoptar estas herramientas. Este hallazgo contradice investigaciones anteriores que generalmente apoyan una asociación positiva entre el reconocimiento de la marca y la intención de comportamiento para utilizar un nuevo producto (García y Yábar, 2023; Izza *et al.*, 2024). Esto sugiere que las asociaciones

de marca con herramientas creativas tradicionales pueden crear resistencia hacia la adopción de soluciones de IA general. Los futuros estudios deberían explorar este fenómeno más a fondo, incorporando potencialmente la investigación cualitativa para entender los sesgos cognitivos y las percepciones de marca que afectan la adopción. Nuestra investigación, centrada en Adobe Firefly, sugiere que esta influencia negativa podría derivar de desajustes entre la identidad establecida de la marca matriz y la nueva oferta de productos (Hem *et al.*, 2003).

Para Adobe, la influencia negativa del reconocimiento de marca en la intención de comportamiento para utilizar herramientas de Gen IA podría derivarse de la falta de autenticidad en el campo de IA generativa. Gen IA es un campo emergente y naciente, por lo tanto, cuando la nueva tecnología se une a una marca bien establecida en otro campo, estas nuevas herramientas podrían aparecer como una desviación no segura del núcleo de la marca. La familiaridad con una marca de buena reputación como Adobe paradójicamente puede aumentar el escrutinio y aumentar las expectativas de nuevos productos. Si bien el reconocimiento de marca influye negativamente en la adopción, probablemente debido a la desalineación entre la identidad de marca establecida y las nuevas ofertas de productos, la confianza de marca reduce esta barrera. Las marcas de confianza alivian las preocupaciones sobre la seguridad de los datos, la fiabilidad y la calidad de salida, fomentando el uso sostenido y la lealtad. Los profesionales prefieren herramientas de marcas en las que confían, lo que reduce los riesgos percibidos y fomenta la adopción a largo plazo. Nuestros hallazgos corroboran estas ideas, demostrando que la confianza de la marca tiene una relación positiva y significativa con la intención de comportamiento de usar el texto de la Gen IA para crear imágenes. Los usuarios que confiaban en Adobe como proveedor de servicios de generación de inteligencia artificial de texto a imagen probablemente adoptaron este servicio y se comprometieron con él. Las investigaciones previas también demuestran que la confianza en una marca tiene una influencia positiva en la intención de comportamiento cuando los usuarios confían en la marca detrás de la tecnología para

cumplir sus promesas y ofrecer una experiencia de usuario positiva (Ameen *et al.*, 2021).

Además, existe el riesgo de que la tecnología de IA general pueda percibirse como un eclipse de la creatividad humana, lo que conduce a una disminución en el uso (Caporusso, 2023). Sin embargo, las marcas de confianza podrían ayudar a mitigar estas percepciones negativas y fomentar una visión más positiva de la contribución de la Gen IA a los campos creativos.

Desde la perspectiva de la gestión de la marca, las estrategias de marketing deben enfatizar los beneficios de rendimiento y alinear las comunicaciones de la marca con las expectativas del usuario. La subimagen de marca puede resolver la desalineación, diferenciando los servicios de IA de las ofertas tradicionales, como se ve en el caso de Adobe. La construcción de la confianza de marca a través de prácticas éticas, asociaciones con influenciadores del sector y mensajería transparente puede mejorar aún más la adopción, asegurando que Gen IA se integre a la perfección en los flujos de trabajo creativos.

La metodología empleada en esta investigación ofrece varias fortalezas y limitaciones que deben ser consideradas. El uso de PLS-SEM proporcionó una validación robusta del modelo de investigación, garantizando la fiabilidad y validez de los hallazgos. Sin embargo, el proceso de selección de muestras, que se basó en encuestas en línea dirigidas a profesionales creativos en España y EE. UU., puede haber introducido sesgo de selección. El tamaño de la muestra solo superó ligeramente el mínimo requerido para aplicar la técnica estadística PLS-SEM. Además, una representación más amplia en los diferentes sectores creativos y regiones geográficas fortalecería la generalización.

La investigación de cómo diferentes disciplinas creativas (por ejemplo, diseño, publicidad, cine) se relacionan con la IA de la generación podría producir ideas más matizadas. En segundo lugar, no se realizó ningún análisis multigrupo, lo que dejó un vacío de investigación en la comprensión de las diferencias entre los grupos en función de la edad, el género, el lugar de residencia o la experiencia previa con la Gen IA, lo que sugiere una dirección para futuras investigaciones. Otra

limitante es la representatividad de la muestra dentro de la industria creativa más amplia. Aunque se utilizó el muestreo aleatorio, la muestra se inclina hacia la dirección creativa y la creación de contenido, con una diversidad limitada en los perfiles creativos de la música o la escritura, lo que podría afectar a la generalización de las conclusiones. Los estudios en el futuro también deberían examinar cómo el encaje de la marca y la ética percibida de la IA influyen en la adopción, dado el creciente discurso en torno a las prácticas éticas de IA. Metodológicamente, el empleo de diseños experimentales para probar la causalidad o la realización de estudios longitudinales para evaluar la evolución de las percepciones a lo largo del tiempo podría enriquecer aún más la comprensión de las tendencias de la adopción de la Gen IA. Otra limitación se relaciona con el ajuste de marca: Adobe fue elegido como el tema principal para los factores de marca, sin embargo, los resultados indicaron una influencia negativa del reconocimiento de marca en la intención conductual. Esto sugiere que la selección de diferentes marcas para futuros estudios puede ayudar a generalizar los hallazgos.

Además, una investigación más a fondo podría ampliar el modelo de medición incorporando otras variables de equidad de marca basadas en el consumidor, como la lealtad a la marca y la calidad percibida, y podría beneficiarse de la comprensión de las expectativas de los usuarios específicos y de los aspectos de marca que no están alineados con su percepción. A pesar de estas limitaciones, este estudio proporciona una base para avanzar en conocimientos teóricos y prácticos sobre la adopción de la Gen IA en las industrias creativas. Si bien este enfoque proporciona información valiosa sobre cómo se adoptan las herramientas de IA en campos creativos, esto puede no capturar plenamente las opiniones de los profesionales en otros sectores con menos familiaridad con la IA.

Conclusiones

En conclusión, el estudio contribuye al creciente conocimiento sobre la adopción de la IA en las industrias creativas, al ofrecer una compren-

sión matizada de las influencias de los factores de equidad de marca basados en el consumidor. Los resultados destacan que la expectativa de rendimiento y las condiciones de facilitación impulsan significativamente al uso, mientras que la confianza de la marca también juega un papel crucial. El reconocimiento de la marca impactó negativamente en la adopción, lo que sugiere que las asociaciones fuertes con herramientas creativas tradicionales pueden crear resistencia a la GEN IA.

Mientras que las marcas basadas en servicios de Gen IA están ganando terreno en el mercado, el panorama académico todavía está desarrollando un marco robusto para ayudar a entender el proceso de adopción y mitigar las barreras. Esta investigación contribuye al creciente cuerpo de evidencia sobre la adopción de la IA general, particularmente en la industria creativa. El estudio también proporciona implicaciones prácticas tanto para los profesionales de la industria creativa como para los gerentes de marca de las marcas basadas en servicios de IA. Desde una perspectiva práctica, estas ideas ayudan a los profesionales creativos, los desarrolladores de IA y los responsables de las políticas a entender los factores y barreras clave para la adopción. Para el campo empírico, esta investigación contribuye a ampliar el marco UTAUT con constructos relacionados con la marca, ofreciendo una perspectiva novedosa sobre la aceptación de la tecnología en las industrias creativas. La investigación futura puede basarse en estos hallazgos explorando las variaciones específicas de la industria, las diferencias interculturales y el papel cambiante de la ética de la IA en las decisiones de adopción. Esta investigación sienta las bases para futuros estudios sobre la adopción de la IA general y ofrece ideas que podrían guiar tanto los avances teóricos como las estrategias prácticas para promover las herramientas de IA en las industrias creativas.

Referencias bibliográficas

- Abbasi, M., Vassilopoulou, P. y Stergioulas, L. (2017). Technology roadmap for the Creative Industries. *Creative Industries Journal*, 10, 40-58. <https://doi.org/10.1080/17510694.2016.1247627>

- Alhwaiti, M. (2023). Acceptance of Artificial Intelligence application in the post-covid era and its impact on faculty members' occupational well-being and teaching self-efficacy: a path analysis using the UTAUT 2 Model. *Applied Artificial Intelligence*, 37(1). <https://doi.org/10.1080/08839514.2023.2175110>
- Anantrasirichai, N. y Bull, D. (2022). Artificial intelligence in the creative industries: A review. *Artificial Intelligence Review*, 55, 589-656. <https://doi.org/10.1007/s10462-021-10039-7>
- Ameen, N., Tarhini, A., Reppel, A. y Anand, A. (2021). Customer experiences in the age of artificial intelligence. *Computers in Human Behavior*, 114, 106548. <https://doi.org/10.1016/j.chb.2020.106548>
- Artechouse. (2023). World of AI Imagination. Artechouse. <https://bit.ly/4aK2Hi3>
- Bagozzi, R. P. y Yi, Y. (1988). On the evaluation of structural equation models. *Journal of the Academy of Marketing Science*, 16(1), 74-94. <https://doi.org/10.1007/BF02723327>
- Bowden, J. L. H. (2014). The process of customer engagement: A conceptual framework. *Journal of Marketing Theory and Practice*, 17(1), 63-74. <https://doi.org/10.2753/MTP1069-6679170105>
- Cabrera-Sánchez, J. P., Villarejo-Ramos, Á. F., Liébana-Cabanillas, F. y Shaikh, A. A. (2021). Identifying relevant segments of AI applications adopters: Expanding the UTAUT2's variables. *Telematics and Informatics*, 58, 101529. <https://doi.org/10.1016/j.tele.2020.101529>
- Caporusso, N. (2023). Generative artificial intelligence and the emergence of creative displacement anxiety. *Research Directs in Psychology and Behavior*, 3(1). <https://doi.org/10.53520/rdpb2023.10795>
- Chatterjee, S., Chaudhuri, R., Vrontis, D., Thrassou, A. y Ghosh, S. K. (2021). Adoption of artificial intelligence-integrated CRM systems in agile organizations in India. *Technological Forecasting and Social Change*, 168, 120783. <https://doi.org/10.1016/j.techfore.2021.120783>
- Chen, J. (2024). The Role of AI: speculative design in redefining artistic collaboration. *Journal of Ecohumanism*, 3(8), 2261-2272. <https://doi.org/10.62754/joe.v3i8.4899>
- Chui, M., Hall, B., Mayhew, H. y Singla, A. (2022, December 6). *The state of AI in 2022 and a half decade in review*. McKinsey & Company. <http://bit.ly/4hYSYrj>
- Chuyen, N. y Vinh, N. (2023). An empirical analysis of predictors of AI-powered design tool adoption. *TEM Journal*, 12(3), 1012-1021. <https://doi.org/10.18421/tem123-28>
- De Almeida Pedro, E., Panizzon, M. y Weber, C. (2023). OHS Professionals AI adoption: A UTAUT Research in Brazilian Industry. *2023 15th IEEE International Conference on Industry Applications (INDUSCON)*, 850-857. <https://doi.org/10.1109/INDUSCON58041.2023.10374850>
- García, M. L. M. y Yábar, D. P. (2023). Impact of brand awareness on consumer loyalty. *Scientific Journal of Applied Social and Clinical Science*, 3(12), 2-9. <https://doi.org/10.22533/at.ed.2163122307068>
- Hair, J. F., Hult, G. T. M., Ringle, C. y Sarstedt, M. (2017). *A primer on partial least squares structural equation modeling (PLS-SEM)* (2nd ed.). Sage.
- Hair, J. F., Risher, J. J., Sarstedt, M. y 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>
- Handayani, W. P. P. (2023). The UTAUT implementation model in defining the behavioral intention of mobile banking users. *Jurnal Manajemen Bisnis*, 14(2), 25-39. <https://doi.org/10.18196/mb.v14i2.18649>
- Hatzius, J., Briggs, J., Kodnani, D., Pierdomenico, G. y Goldman Sachs & Co. LLC. (2023). *The potentially large effects of artificial intelligence on economic growth* (By Goldman Sachs & Co. LLC). <https://bit.ly/3EIOOKX>
- Hem, L. E., De Chernatony, L. e Iversen, N. M. (2003). Factors influencing successful brand extensions. *Journal of Marketing Management*, 19(7-8), 781-806. <https://doi.org/10.1362/026725703322498109>
- Hess, J. y Story, J. (2005). Trust-based commitment: Multidimensional consumer-brand relationships. *Journal of Consumer Marketing*, 22(6), 313-322. <https://doi.org/10.1108/07363760510623902>
- Izza, A. M., Ardiansyah, M. N., Barkah, F. y Romdonny, J. (2024). Synergistic effects of content marketing and influencers marketing on the formation of brand awareness and purchase interest of TikTok Shop users (Cirebon City case study). *International Journal of Social Service and Research*, 4(5), 1339-1347. <https://doi.org/10.46799/ijssr.v4i05.781>
- Jiang, J., Ma, J., Huang, X., Zhou, J. y Chen, T. (2024). Extend UTAUT2 model to analyze user behavior of China Construction Bank Mobile App. *SAGE Open*, 14(4). <https://doi.org/10.1177/21582440241287070>

- Kathuria, S., Bansal, H. y Balhara, S. (2018). Impact of Brand Recognition on Consumer Attraction: A Study of Telecom Sector. *Researchers World, Journal of Arts Science & Commerce*, 9(1), 57-63. <https://doi.org/10.18843/rwjasc/v9i1/07>
- Maican, C., Sumedrea, S., Tecău, A., Nichifor, E., Chițu, I., Lixândroi, R. y Brătucu, G. (2023). Factors influencing the behavioural intention to use AI-generated images in business. *Journal of Organizational and End User Computing*. <https://doi.org/10.4018/joeuc.330019>
- Menon, D. y Shilpa, K. (2023). Chatting with ChatGPT: Analyzing the factors influencing users' intention to use OpenAI's ChatGPT using the UTAUT model. *Heliyon*, 9(11). <https://doi.org/10.1016/j.heliyon.2023.e20962>
- Rios, R. E. y Riquelme, H. (2010). Sources of brand equity for online companies. *Journal of Research in Interactive Marketing*, 4(3), 214-240. <https://doi.org/10.1108/17505931011070587>
- Roets, C. R. Q., Bevan-Dye, A. L. y Viljoen, W. P. (2014). Influence of social image and brand trust on mobile phone brand equity amongst African Generation Y students. *Mediterranean Journal of Social Sciences*, 5(21), 75-84. <https://doi.org/10.5901/mjss.2014.v5n21p75>
- Rubio, N., Oubiña, J. y Villaseñor, N. (2014). Brand awareness-Brand quality inference and consumers' risk perception in store brands of food products. *Food Quality and Preference*, 32, 289-298. <https://doi.org/10.1016/j.foodqual.2013.09.006>
- Sanchez, T. (2023). Examining the text-to-image community of practice: Why and how do people prompt generative AIs? *Creativity and Cognition*. <https://doi.org/10.1145/3591196.359305>
- Sanmukhiya, C. (2020). A PLS-SEM approach to the UTAUT model: the case of Mauritius. *Annals of Social Sciences & Management Studies*, 6(1). <https://doi.org/10.19080/asm.2020.06.555677>
- Sasmita, J. y Mohd Suki, N. (2015). Young consumers' insights on brand equity: Effects of brand association, brand loyalty, brand awareness, and brand image. *International Journal of Retail & Distribution Management*, 43(3), 276-292. <https://doi.org/10.1108/IJRDM-02-2014-0024>
- Smith, C. (2022, December 22). *The unreal exhibition showcases AI-handling talents of 'prompt writers'. trend hunter*. <http://bit.ly/3EgCX0S>
- Soper, D. S. (2024). A-priori sample size calculator for structural equation models [Software]. <https://bit.ly/4hPigrm>
- Upadhyay, N., Upadhyay, S. y Dwivedi, Y. K. (2022). Theorizing artificial intelligence acceptance and digital entrepreneurship model. *International Journal of Entrepreneurial Behaviour & Research*, 28(5), 1138-1166. <http://dx.doi.org/10.1108/IJEBr-01-2021-0052>
- Venkatesh, V., Morris, M., Davis, G. B. y Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. *MIS Quarterly*, 27(3), 425-478. <https://doi.org/10.2307/30036540>
- Venkatesh, V., Thong, J. Y. y Xu, X. (2012). Consumer acceptance and use of information technology: Extending the unified theory of acceptance and use of technology. *MIS Quarterly*, 36(1), 157-178. <https://doi.org/10.2307/41410412>
- Vinchon, F., Lubart, T., Bartolotta, S., Gironnay, V., Botella, M., Bourgeois-Bougrine, S., Burkhardt, J., Bonnardel, N., Corazza, G. E., Glăveanu, V., Hanson, M. H., Ivcevic, Z., Karwowski, M., Kaufman, J. C., Okada, T., Reiter-Palmon, R. y Gaggioli, A. (2023). Artificial intelligence and creativity: A manifesto for collaboration. *The Journal of Creative Behavior*, 57(4), 472-484. <https://doi.org/10.1002/jocb.597>
- Wang, H., Fu, T., Du, Y., Gao, W., Huang, K., Liu, Z., Chandak, P., Liu, S., Van Katwyk, P., Deac, A., Anandkumar, A., Bergen, K., Gomes, C. P., Ho, S., Kohli, P., Lasenby, J., Leskovec, J., Liu, T., Manrai, A. y Zitnik, M. (2023). Scientific discovery in the age of artificial intelligence. *Nature*, 620(7972), 47-60. <https://doi.org/10.1038/s41586-023-06221-2>
- Wang, H., Wei, J. y Yu, C. (2008). Global brand equity model: Combining customer-based with product-market outcome approaches. *Journal of Product & Brand Management*, 17(5), 305-316. <https://doi.org/10.1108/10610420810896068>
- Westland, J. C. (2010). Lower bounds on sample size in structural equation modeling. *Electronic Commerce Research and Applications*, 9(6), 476-487. <https://doi.org/10.1016/j.ele-rap.2010.07.003>
- Yin, M., Han, B., Ryu, S. y Min, H. (2023). Acceptance of generative AI in the creative industry: Examining the role of AI anxiety in the UTAUT2 model. In *Lecture Notes in Computer Science*, 14059, 288-310. https://doi.org/10.1007/978-3-031-48057-7_18
- Zhang, W. (2020). A study on the user acceptance model of artificial intelligence music based on UTAUT. *Journal of the Korea Society of Computer and Information*, 25(1), 25-33. <https://doi.org/10.9708/jksoci.2020.25.06.025>