

Artículo de Investigación

# Impacto y Perspectivas de la Inteligencia Artificial Generativa en la Educación Superior: Un Estudio sobre la Percepción y Adopción Docente usando el modelo AETGE/GATE

## Impact and Perspectives of Generative Artificial Intelligence in Higher Education: A Study on Lecturers' Perception and Adoption using the AETGE/GATE Model

Juana María Padilla Piernas<sup>1</sup>: Universidad Católica de Murcia, España.

[jmpadilla@ucam.edu](mailto:jmpadilla@ucam.edu)

María del Mar Martín García: Universidad Isabel I, España.

[mariadelmar.martin.garcia@ui1.es](mailto:mariadelmar.martin.garcia@ui1.es)

Fecha de Recepción: 30/05/2024

Fecha de Aceptación: 21/08/2024

Fecha de Publicación: 30/08/2024

### Cómo citar el artículo (APA 7<sup>a</sup>):

Padilla Piernas, J. M. y Martín García, M. M. (2024). Impacto y Perspectivas de la Inteligencia Artificial Generativa en la Educación Superior: Un Estudio sobre la Percepción y Adopción Docente usando el modelo AETGE/GATE [Impact and Perspectives of Generative Artificial Intelligence in Higher Education: A Study on Lecturers' Perception and Adoption using the AETGE/GATE Model]. *European Public & Social Innovation Review*, 9, 01-21. <https://doi.org/10.31637/epsir-2024-595>

### Resumen:

**Introducción:** La inteligencia artificial (IA) generativa está transformando la educación superior, ofreciendo la oportunidad de mejorar tanto la enseñanza como el aprendizaje. Esta

<sup>1</sup> Autor Correspondiente: Juana María Padilla Piernas. Universidad Católica de Murcia (España).

tecnología permite personalizar el aprendizaje y ofrece herramientas avanzadas para la tutoría y el análisis predictivo de resultados académicos. **Metodología:** Este estudio utiliza el modelo AETGE/GATE para evaluar las percepciones de profesores universitarios españoles sobre la utilidad, facilidad de uso, valor percibido, expectativas, influencia social, condiciones facilitadoras y preocupaciones éticas de la IA generativa. Los datos se recopilaban mediante un cuestionario y se analizaron con SPSS versión 29.0.1.0. **Resultados:** Los análisis revelan que no hay diferencias significativas entre hombres y mujeres en la percepción de utilidad, facilidad de uso y valor percibido. Sin embargo, las mujeres mostraron mayores influencias sociales, condiciones facilitadoras y preocupaciones éticas. **Discusión:** Los resultados sugieren que, aunque la percepción general de la IA generativa es positiva, existen diferencias de género en ciertos aspectos, como la influencia social y las preocupaciones éticas. Esto indica la necesidad de programas de formación y apoyo adaptados a diferentes grupos demográficos. **Conclusiones:** Este estudio revela la percepción y adopción de la IA generativa entre profesores universitarios, destacando la necesidad de superar barreras para una implementación efectiva en la educación superior.

**Palabras clave:** Inteligencia Artificial Generativa; UTAUT; TAM; VAM; educación superior; profesores; AETGE; Nuevas Tecnologías.

**Abstract: Introduction:** Generative artificial intelligence (AI) is transforming higher education, offering the opportunity to improve both teaching and learning. This technology enables personalised learning and offers advanced tools for tutoring and predictive analysis of academic outcomes. **Methodology:** This study utilises the AETGE/GATE model to assess the perceptions of Spanish university lecturers regarding the usefulness, ease of use, perceived value, expectations, social influence, facilitating conditions, and ethical concerns of generative AI. Data were collected through a questionnaire and analysed using SPSS version 29.0.1.0. **Results:** The analyses reveal no significant differences between men and women in their perceptions of usefulness, ease of use, and perceived value. However, women exhibited greater social influences, facilitating conditions, and ethical concerns. **Discussion:** The results suggest that, while the overall perception of generative AI is positive, there are gender differences in certain aspects, such as social influence and ethical concerns. This indicates the need for training and support programmes tailored to different demographic groups. **Conclusions:** This study highlights the perception and adoption of generative AI among university professors, underscoring the necessity to overcome barriers for effective implementation in higher education.

**Keywords:** Generative Artificial Intelligence; UTAUT; TAM; VAM; higher education; professors; AETGE; New Technologies.

## 1. Introducción

La inteligencia artificial (IA) ha experimentado un crecimiento exponencial en la última década, convirtiéndose en una tecnología disruptiva con aplicaciones en múltiples sectores. En particular, ha sido el desarrollo de la IA Generativa (IAG), de la mano de Chat GPT y Dall-E (OpenAI), Copilot (Microsoft), Bard que ahora se llama Gemini (Google), Llama (Meta), Claude (Anthropic), Perplexity o Mistral entre otros, que permiten crear contenido nuevo y realista, los que están transformando rápidamente el panorama de la educación superior (Dans, 2024; Bryson, 2018; Bryson y Theodorou, 2019). Esta tecnología no solo tiene el potencial de mejorar la personalización del aprendizaje y la eficiencia administrativa, sino que también plantea desafíos éticos y prácticos significativos que deben ser abordados para su adopción efectiva (Hemachandran *et al.*, 2022; Yeralan y Lee, 2023; Zhai *et al.*, 2021). Además, la IAG, puede revolucionar la educación superior proporcionando herramientas avanzadas para la

tutoría, el análisis predictivo de resultados académicos y la personalización del contenido educativo (Hemachandran *et al.*, 2022). Estas aplicaciones permiten a los estudiantes aprender a su propio ritmo, eliminando barreras tradicionales y proporcionando un entorno de aprendizaje más inclusivo y adaptado a las necesidades individuales del alumnado. Sin embargo, la implementación de esta tecnología también enfrenta obstáculos, como la resistencia al cambio por parte del profesorado y preocupaciones sobre la privacidad y la equidad (Zhai *et al.*, 2021; Bryson, 2015).

Para comprender mejor cómo los profesores universitarios perciben la adopción de la IAG y su potencial impacto, se ha desarrollado el modelo AETGE/GATE (Adopción y Evaluación de Tecnología Generativa en Educación). Este modelo surge de la combinación de varios modelos teóricos bien establecidos, como el Modelo de Aceptación de Tecnología (TAM) diseñado por Davis (1989), la Teoría Unificada de la Aceptación y Uso de la Tecnología (UTAUT) diseñada por Venkatesh *et al.* (2003); y el Modelo de aceptación de Valor (VAM), proporcionando así un marco comprensivo para evaluar las percepciones y la aceptación de la IAG en el ámbito universitario. El modelo AETGE/GATE se estructura en torno a varios componentes clave, incluyendo la expectativa de rendimiento, el valor percibido, la facilidad de uso percibida, la influencia social, las condiciones facilitadoras, la actitud hacia el cambio tecnológico y el impacto educativo. Cada uno de estos componentes se ha identificado como crítico para entender la adopción de nuevas tecnologías en contextos educativos y permite una evaluación detallada de las percepciones y actitudes del profesorado hacia la IA generativa (Bryson *et al.*, 2018; Bryson y Theodorou, 2019).

Los objetivos de este estudio son:

- (1) analizar las percepciones y actitudes de los profesores universitarios hacia la IA generativa,
- (2) identificar las barreras y facilitadores de su adopción, y
- (3) evaluar el impacto potencial de esta tecnología en la educación superior.

Por último, cabe resaltar que en un contexto donde la IA está transformando rápidamente diversos aspectos de la sociedad, incluyendo la educación, es fundamental entender cómo los educadores perciben y se adaptan a estos cambios. Los resultados de este trabajo proporcionarán información de interés para investigadores y administradores universitarios, ayudando a guiar la implementación efectiva de la IAG en el ámbito educativo. Además, este estudio contribuirá a la creciente literatura sobre la IA aplicada a la educación superior, abordando las preocupaciones éticas y prácticas que surgen de esta convergencia tecnológica (Bryson, 2015; Goodman y Flaxman, 2016; Bryson y Winfield, 2017; Stewart *et al.*, 2018).

### **1.1. Evolución de la IA Generativa**

La IAG ha evolucionado significativamente desde que John McCarthy acuñó el término "IA" en 1956. Inicialmente centrada en la resolución de problemas y toma de decisiones, la IA comenzó a aplicarse en industrias como la farmacéutica y química en la década de 1980, preparándose para su futura expansión a otras industrias (National Geographic España, 2020; Pareto, s.f.). En las últimas dos décadas, la IAG ha emergido como un subcampo crucial, impulsada por avances en hardware y grandes conjuntos de datos. Las Redes Neuronales Convolucionales (CNN) y Recurrentes (RNN) introducidas en los años 90 sentaron las bases para innovaciones posteriores (Hochreiter y Schmidhuber, 1997). La arquitectura Transformer, presentada por Vaswani *et al.* en 2017, revolucionó el procesamiento del lenguaje natural,

facilitando el desarrollo de modelos como BERT (Devlin *et al.*, 2018) y la serie GPT (Radford *et al.*, 2018, 2019; Brown *et al.*, 2020). Modelos como GPT-3 demostraron capacidades sin precedentes en generación de texto, marcando un hito en la historia de la IAG. Recientemente, modelos avanzados como GPT-4 y LaMDA, y aplicaciones como ChatGPT, han democratizado el acceso a la IAG, ampliando su uso desde la generación de contenido hasta la asistencia en análisis y toma de decisiones (OpenAI, 2023; Thoppilan *et al.*, 2022).

## 1.2. Principales Hitos y Avances Tecnológicos en la IA Generativa

La evolución de la inteligencia artificial generativa ha estado marcada por una serie de hitos y avances tecnológicos significativos que han transformado el campo y ampliado sus aplicaciones. Entre los más destacados se encuentran los que se detalla a continuación.

La introducción de GANs (Generative Adversarial Networks) y su impacto. Fueron introducidas por Goodfellow *et al.* (2014), representaron un avance revolucionario en la IA generativa. Las GANs consisten en dos redes neuronales que compiten entre sí: un generador que crea datos sintéticos y un discriminador que intenta distinguir entre datos reales y generados. Este enfoque ha permitido la creación de contenido con un nivel de realismo sin precedentes, impulsando aplicaciones en campos como el arte digital, el diseño y la síntesis de datos. En el contexto educativo, las GANs han demostrado potencial para generar ejemplos de estudio realistas y simulaciones complejas para mejorar el aprendizaje experiencial.

Desarrollo y aplicación de modelos como GPT-3: El modelo GPT-3 (Generative Pre-trained Transformer 3), desarrollado por OpenAI en 2020, marcó un hito en el procesamiento del lenguaje natural. Este modelo, con una arquitectura de 175 mil millones de parámetros, exhibió una habilidad extraordinaria para producir texto coherente y ejecutar una variedad de tareas lingüísticas con mínimas instrucciones. Su impacto se ha extendido a múltiples campos, desde la generación de contenido creativo hasta la asistencia en programación y análisis de datos (Brown *et al.*, 2020).

Implementaciones exitosas en el ámbito educativo: La IAG ha encontrado aplicaciones significativas en el sector educativo. Sistemas basados en GPT-3 y modelos similares se han utilizado para crear experiencias de aprendizaje personalizadas, generar evaluaciones adaptativas y proporcionar apoyo continuo a los estudiantes. Estas implementaciones han demostrado potencial para mejorar la personalización del aprendizaje y aumentar la eficiencia en la enseñanza (Márquez, *et al.*, 2023; Humphry y Fuller, 2023; Humphry y Fuller, 2023). Por ejemplo, plataformas de aprendizaje adaptativo que utilizan IAG pueden ajustar el contenido y el ritmo de enseñanza en tiempo real basándose en el rendimiento y las necesidades individuales de los estudiantes

Avances en Modelos Multimodales. Los últimos avances en IAG han generado modelos capaces de procesar y generar contenido en múltiples modalidades (texto, imagen, audio, video) de manera integrada. Según Dans (2024), esto abre nuevas posibilidades para crear materiales educativos interactivos y multisensoriales, mejorando la experiencia de aprendizaje y la accesibilidad para estudiantes con diversos estilos de aprendizaje y necesidades.

Además, el informe de McKinsey (2024), subraya un rápido crecimiento en la adopción de IA generativa en el ámbito empresarial, con un 65% de las organizaciones utilizándola regularmente en al menos una función. Este crecimiento refleja el impacto transformador de la IA en diversos sectores, incluida la educación superior. Sin embargo, se presentan desafíos significativos como la inexactitud en la generación de contenido y riesgos de infracción de propiedad intelectual. Estos retos subrayan la necesidad de un desarrollo e implementación

responsables de estas tecnologías, especialmente en contextos educativos donde la precisión e integridad académica son cruciales.

Para concluir, queda patente que los hitos y avances tecnológicos en IA generativa han transformado el panorama de la educación superior, abriendo nuevas posibilidades para personalizar y enriquecer la experiencia de aprendizaje. No obstante, el éxito de su implementación depende de un delicado equilibrio entre la innovación tecnológica y las consideraciones éticas y pedagógicas fundamentales.

### *1.3. Machine Learning y Deep Learning: Fundamentos y Aplicaciones*

El Machine Learning (ML) y el Deep Learning (DL) son pilares fundamentales en el desarrollo de la Inteligencia Artificial Generativa (IAG), con aplicaciones cada vez más relevantes en el ámbito de la educación superior. A continuación, se evalúan los fundamentos de estas tecnologías y su impacto transformador en los procesos de enseñanza y aprendizaje.

El Machine Learning (ML), es una rama fundamental de la inteligencia artificial, se centra en el desarrollo de algoritmos y modelos capaces de aprender y realizar predicciones basadas en datos. A diferencia de los programas tradicionales que siguen una serie de instrucciones predefinidas, los sistemas de ML identifican patrones y adaptan sus acciones en consecuencia. A su vez, este campo se subdivide principalmente en aprendizaje supervisado (utilizado en aplicaciones educativas como la predicción del rendimiento académico y la personalización de contenidos), no supervisado (aplicado en la segmentación de estudiantes y la identificación de patrones de aprendizaje) y semi-supervisado. Cada uno con metodologías y aplicaciones específicas para cada sector, desde la detección de fraudes a la segmentación de mercados, (Ongsulee, 2017).

El Deep Learning (DL), es una subdisciplina avanzada del ML, emplea redes neuronales profundas con múltiples capas para aprender representaciones complejas de los datos. Las Redes Neuronales Convolucionales (CNNs) han demostrado ser particularmente eficaces en el procesamiento de imágenes, facilitando aplicaciones como el reconocimiento facial y la detección de objetos. Por otro lado, las Redes Neuronales Recurrentes (RNNs) se adaptan perfectamente a los datos secuenciales, como el procesamiento del lenguaje natural y el análisis de series temporales, permitiendo el desarrollo de tutores virtuales y sistemas de retroalimentación automática. Los Autoencoders, se utilizan para la reducción de dimensionalidad y la detección de anomalías, con aplicaciones que abarcan desde la eliminación de ruido en imágenes hasta la identificación de transacciones fraudulentas. En el sector educativo sus aplicaciones se centran en la identificación de patrones atípicos en el comportamiento de aprendizaje y la personalización de contenidos educativos (Anusha y Nagaraja, 2021).

Sin duda, los avances en ML y DL han evidenciado un potencial transformador en diversos sectores industriales. En el ámbito de la salud, por ejemplo, la integración del análisis de big data con técnicas de ML y DL promete mejorar significativamente la precisión diagnóstica y personalizar los tratamientos. No obstante, esta integración enfrenta importantes desafíos, como la interoperabilidad de los sistemas y la gestión eficiente de volúmenes masivos de datos (Raghupathi y Raghupathi, 2014). En el campo de la detección de anomalías, los modelos autoencoder han demostrado una eficacia notable en la identificación de valores atípicos en conjuntos de datos multivariados, resultando particularmente útiles en la detección de fraudes y la optimización de la seguridad en redes. Sin embargo, la integración de Big data e inteligencia artificial plantea importantes consideraciones éticas, especialmente en lo que respecta a la privacidad y seguridad de los datos. Para la implementación exitosa de estas



tecnologías se requiere no solo de una infraestructura robusta sino también un marco normativo claro que aborde estos desafíos y maximice las oportunidades que ofrecen estas innovaciones tecnológicas (Lee y Yoon, 2017). En resumen, tanto el ML como el DL están promoviendo una transformación profunda en múltiples industrias al proporcionar herramientas sofisticadas para el análisis y la predicción basados en datos. No obstante, su implementación efectiva demanda una gestión meticulosa de los desafíos técnicos y éticos asociados.

#### *1.4. Aplicación de la IAG en el Contexto Educativo*

La inteligencia artificial generativa está revolucionando el panorama educativo al permitir la creación de contenidos innovadores a partir de datos existentes. Esta tecnología emergente y disruptiva está redefiniendo la forma en que se diseñan y entregan los materiales educativos, haciendo que el aprendizaje sea más accesible y personalizado. De acuerdo con Zhang y Aslan (2021), la IAG tiene la capacidad de desarrollar textos, ejercicios y exámenes adaptados a las necesidades específicas de cada estudiante. Por lo tanto, su uso facilita la creación de materiales educativos dinámicos que pueden ajustarse en tiempo real al progreso y estilo de aprendizaje individual. La IAG también puede proporcionar asistencia automatizada, funcionando como un tutor virtual con explicaciones adicionales y retroalimentación en tiempo real, ayudando a los estudiantes a comprender mejor los conceptos y mejorar su rendimiento académico de manera continua (Zawacki-Richter *et al.*, 2019). Este tipo de asistencia es particularmente útil para resolver dudas fuera del horario de clases, ofreciendo soporte constante a los estudiantes. Asimismo, la IAG puede brindar servicios de apoyo académico inteligentes. La implementación de chatbots y asistentes virtuales basados en IAG ayuda a los estudiantes con tareas administrativas y académicas, respondiendo preguntas frecuentes y proporcionando información sobre recursos educativos de manera eficiente (Ifenthaler y Schumacher, 2023). Estos servicios pueden mejorar el acceso a la información y aliviar la carga administrativa sobre el personal académico. Por último, la IAG supone una innovación en los métodos de enseñanza, facilitando la implementación de enfoques pedagógicos avanzados, como la enseñanza basada en proyectos y el aprendizaje colaborativo.

Estos métodos innovadores no solo mejoran la comprensión de los conceptos, sino que también desarrollan habilidades críticas para el futuro profesional de los estudiantes (Zhang y Aslan, 2021). Es importante señalar que, si bien Baker (2016) argumenta que los sistemas de tutoría basados en IA no pueden reemplazar completamente a los tutores humanos, es evidente que pueden complementar eficazmente la enseñanza tradicional, ofreciendo nuevas oportunidades para la innovación pedagógica.

En conclusión, la integración de la IAG en la educación superior ofrece oportunidades sin precedentes para personalizar la educación, mejorar la eficiencia administrativa y fomentar la innovación pedagógica. Sin embargo, es crucial que su implementación se realice de manera reflexiva y ética, garantizando que la tecnología sirva como un complemento y no como un reemplazo de la interacción humana en el proceso educativo (Ongsulee, 2017; Lee y Yoon, 2017). El desafío para las instituciones de educación superior radica en aprovechar estas tecnologías de manera que mejoren la calidad de la educación mientras se abordan las preocupaciones éticas y se mantiene el valor fundamental de la interacción humana en el aprendizaje.

### 1.5. Modelos Teóricos Utilizados

Para el análisis de la percepción y adopción de la IAG en la educación superior, se han empleado varios modelos teóricos bien establecidos y utilizados por los académicos. Dichos modelos proporcionan el marco conceptual para entender los factores que influyen en la aceptación de nuevas tecnologías por parte del profesorado. A continuación, se describen los distintos modelos y sus principales características.

**Modelo de Aceptación de Tecnología (TAM) de Davis (1989).** Es un modelo que explica la aceptación y uso de una tecnología, destacando la percepción de facilidad de uso y utilidad como determinantes de la intención y uso real. En la IA generativa, el TAM mide cómo los profesores perciben estas tecnologías y cómo estas percepciones influyen en su intención de adoptarlas en sus prácticas educativas (Davis, 1989).

**Teoría Unificada de la Aceptación y Uso de la Tecnología (UTAUT) de Venkatesh et al. (2003).** La UTAUT amplía el TAM e incluye la expectativa de esfuerzo, expectativa de rendimiento, influencia social y condiciones facilitadoras, que influyen en la intención y comportamiento de uso. Este modelo evalúa cómo factores como la influencia social y el apoyo institucional afectan la adopción de la IA generativa entre los profesores universitarios (Venkatesh et al., 2003).

**Modelo de Aceptación de Valor (VAM).** Se centra en el valor percibido de una tecnología, considerando beneficios y sacrificios percibidos (costes y esfuerzo). Es útil para evaluar cómo el profesorado valora los beneficios de la IA generativa (personalización del aprendizaje, eficiencia administrativa) en relación con los costes y esfuerzos de su adopción (Kim et al., 2007).

### 1.6. Integración de los modelos TAM, UTAUT y VAM

Los modelos teóricos presentados han guiado el análisis de la percepción y adopción de la IA generativa en la educación superior, proporcionando un marco integral para entender los factores que influyen en su adopción (Bryson et al., 2017; Bryson y Theodorou, 2019). La integración de estos modelos permite una comprensión holística de los factores que influyen en la adopción de nuevas tecnologías en el contexto educativo (Scherer et al., 2019). Estudios recientes respaldan la relevancia de esta integración en el contexto de la IA generativa en la educación superior (Dwivedi et al., 2019; Zhu et al., 2018; Cheng, 2019).

### 1.7. Ética y Privacidad en el Uso de la IA Generativa

La integración de la IAG en la educación superior presenta desafíos éticos y de privacidad que afectan la percepción y aceptación de estas tecnologías por parte del profesorado. La integridad académica es una preocupación principal, ya que la dificultad para detectar contenido generado por IA puede llevar a acusaciones falsas y dudas sobre la autenticidad de las evaluaciones (Zohny et al., 2023). Además, la capacidad de la IAG para crear textos convincentes aumenta las preocupaciones sobre el plagio y la equidad en las evaluaciones (Irfan et al., 2023). Por otro lado, los modelos de IA pueden contener sesgos que afectan desproporcionadamente a ciertos grupos de estudiantes, como los internacionales o de minorías étnicas, lo que subraya la necesidad de equidad en las evaluaciones basadas en IA (Kadaruddin, 2023). Estos sesgos pueden surgir de los datos de entrenamiento, requiriendo atención para asegurar evaluaciones justas (Zohny et al., 2023).

La privacidad de los datos es otra preocupación significativa. Los estudiantes muestran preocupaciones sobre la privacidad de sus datos al usar herramientas de IA, y la recopilación y análisis de datos personales plantean riesgos de seguridad que deben ser gestionados adecuadamente (Irfan *et al.*, 2023; Gasimova, 2023). La confianza en la protección de los datos es fundamental para la adopción de estas tecnologías.

Es crucial fomentar la alfabetización digital y la competencia en IA entre estudiantes y profesores para asegurar el uso ético y efectivo de estas tecnologías (Kadaruddin, 2023). La formación en habilidades digitales ayuda a los estudiantes a utilizar las herramientas de IA de manera responsable y capacita a los educadores para integrarlas en sus métodos de enseñanza (Zohny *et al.*, 2023). A su vez, las universidades deberán desarrollar políticas claras para guiar el uso de la IA en la educación, asegurando que se respeten las normas éticas y se promueva un entorno inclusivo (Irfan *et al.*, 2023). La transparencia en el uso de IA y la responsabilidad en su implementación son esenciales para mitigar los riesgos y asegurar la confianza en estas tecnologías (Whittaker *et al.*, 2023).

En conclusión, la integración de la IA generativa en la educación superior ofrece oportunidades y desafíos. Para una implementación responsable, es esencial abordar las preocupaciones sobre la integridad académica, los sesgos, la privacidad de los datos y la necesidad de alfabetización en IA. Además, el desarrollo de políticas institucionales claras y la promoción de la transparencia y la responsabilidad son fundamentales. Un enfoque colaborativo y multidisciplinario puede ayudar a mitigar los riesgos y maximizar los beneficios de estas tecnologías en el ámbito educativo (Irfan *et al.*, 2023).

## 2. Metodología

### 2.1. Diseño del estudio

Este estudio utiliza el modelo AETGE (Adopción y Evaluación de Tecnología Generativa en Educación), diseñado específicamente para evaluar cómo el personal docente e investigador de las universidades españolas perciben la adopción y el impacto de la IA generativa en el desempeño de su labor docente. El modelo AETGE integra y adapta elementos de teorías establecidas en la adopción de la tecnología y del marketing digital al contexto universitario, como el TAM (Modelo de Aceptación de Tecnología), el VAM (Modelo de aceptación de Valor) y el UTAUT (Teoría Unificada de la Aceptación y Uso de la Tecnología). El diseño de esta investigación está orientado a explorar diversos aspectos de la adopción de la IA generativa en la educación superior, incluyendo la percepción de utilidad, la facilidad de uso percibida, el valor percibido, la expectativa de rendimiento, la influencia social, las condiciones facilitadoras y las expectativas y preocupaciones del docente en la Universidad española.

### 2.2. Recolección de datos y muestra

Los datos se recogen a través de un formulario autoadministrado en Google Forms. Los ítems se diseñaron teniendo en cuenta estos tres modelos combinados ya utilizados por otros autores y adaptado a las características del sector educativo. Este modelo se aplica a una muestra de personal docente de diferentes categorías y áreas de conocimiento de las universidades españolas. El cuestionario fue enviado por correo electrónico a las universidades en el mes de abril de 2024. Es importante señalar que este trabajo constituye un estudio piloto diseñado para validar el modelo AETGE y sus constructos. Se obtuvieron un total de 87 cuestionarios válidos que posteriormente se utilizaron en el análisis de datos. El tamaño de la muestra, aunque modesto, se considera adecuado para esta fase exploratoria, proporcionando perspectivas valiosas sobre las percepciones y actitudes hacia la IA generativa en educación



superior. Este enfoque es consistente con las recomendaciones de Hair *et al.* (2010) para estudios piloto en el desarrollo de nuevos modelos.

### 2.3. Instrumento de medición

El cuestionario, basado en el modelo AETGE, fue sometido a un riguroso proceso de validación. Se realizó una prueba piloto con un grupo reducido de expertos en tecnología educativa, seguida de ajustes basados en sus comentarios. El instrumento final abarcó dimensiones clave en la adopción e intención de uso de la tecnología, como la utilidad percibida, facilidad de uso, influencia social, condiciones facilitadoras, valor percibido y expectativa de rendimiento. En esta investigación se emplean un total de 8 variables, cuya medición se llevó a cabo con al menos dos ítems por variable, para poder comprobar que todas ellas estaban compuestas por un porcentaje adecuado de varianza fiable y poder identificar, del mismo modo, la varianza error de estas.

En la tabla 1 se muestra la denominación de cada variable, su definición, el modelo utilizado para la construcción de los ítems y el número de ellos con los que se ha medido cada variable. La fiabilidad se estimó mediante el procedimiento de Alfa de Cronbach mostrando, en todas las variables, excepto en la Influencia social y las Preocupaciones, valores por encima de 0,7, cumpliendo así la fiabilidad de los ítems utilizados en la escala. Sobre la base de que esta investigación es una exploración preliminar, los ítems correspondientes a la variable Influencia social y Preocupaciones, serán revisados y reformulados. Todas las variables se midieron a través de una escala de Likert de 5 puntos, donde 1 es “nada”, 2 es “poco”, 3 es “moderadamente”, 4 es “mucho” y 5 “extremadamente”.

El cuestionario se estructuró en torno a tres bloques, además de las preguntas relativas al perfil sociodemográfico de la muestra. En el bloque primero se han abordado las cuestiones relativas a la percepción de utilidad y de facilidad de uso, basadas en el modelo TAM. En el segundo bloque se ha medido el valor percibido, utilizando los ítems adaptados del modelo VAM. El tercer bloque, utilizando el modelo UTAUT, ha medido la expectativa de rendimiento, la influencia social y las condiciones facilitadoras. Finalmente se añadió un bloque sobre expectativas y preocupaciones.

**Tabla 1.**

#### *Definición de variables*

Nombre de la variable	Definición de la variable	Nº ítems	Alfa Cronbach
<b>Percepción de utilidad (Modelo TAM)</b>	Grado de creencia en que el uso de la IAG mejorará su desempeño docente	4	0.831
<b>Percepción facilidad uso (Modelo TAM)</b>	Grado en que se percibe que aprender y utilizar la IAG será sencillo	4	0.755
<b>Valor percibido (VAM)</b>	Evaluación general sobre la relación entre los beneficios y los costos de usar la IAG	4	0.793
<b>Expectativa de rendimiento Modelo (UTAUT)</b>	Grado de creencia que el uso de la IAG mejorará su desempeño en actividades específicas	2	0.805
<b>Influencia social Modelo (UTAUT)</b>	Grado en que se percibe que el entorno social universitario cree que debería usar la IAG	2	0.527

<b>Condiciones facilitadoras Modelo (UTAUT)</b>	Percepción de apoyo institucional necesario para usar la IAG	2	0.838
<b>Expectativas</b>	Grado de entusiasmo en la adopción de la IAG	2	0.725
<b>Preocupaciones</b>	Grado de preocupación desde un punto de vista ético en el uso de la IAG en la educación	2	0.559

**Fuente:** Elaboración propia (2024)

En la tabla 2 se muestra el perfil demográfico de la muestra, compuesta por 43 hombres y 44 mujeres, la mayoría menor de 45 años. Para completar el perfil del encuestado en referencia al objeto de este estudio, se les preguntó por su nivel de conocimiento y habilidad en el uso de las herramientas de IA generativa. Se encontró que más del 40 % de la muestra califica su nivel como bajo o muy bajo, cifra muy superior a los que lo consideran como alto o muy alto.

**Tabla 2.**

*Frecuencias de características de la muestra*

<b>Género</b>		<b>Frecuencia</b>	<b>Porcentaje</b>
	Hombre	43	49,4
	Mujer	44	50,6
	<b>Edad</b>		
	36-45	32	36,7
	46-55	16	18,4
	55-64	8	9,2
	65 o más	1	1,1
	Menor de 35 años	30	34,5
	<b>Categoría</b>		
	Catedrático de Universidad	1	1,1
	Colaborador	1	1,1
	Contratada/o FPU	7	6,7
	Profesor Ayudante Doctor	13	14,9
	Profesor colaborador	1	1,1
	Profesor Contratado Doctor	18	20,7
	Profesor Sustituto Interino	7	8,0
	Profesor Titular Universidad	11	12,6
	Profesor Universidad Privada	29	33,3
	<b>¿Cómo calificaría su nivel de conocimiento y habilidad actual en el uso de herramientas de IA generativa?</b>		
	Alto	13	14,9
	Bajo	32	36,8
	Medio	31	35,6
	Muy alto	5	5,7
	Muy bajo	6	6,9
	Total	87	100,0

**Fuente:** Elaboración propia (2024)

## 2.4. Análisis de datos

Los datos recopilados fueron analizados utilizando técnicas estadísticas descriptivas e inferenciales. Todos los análisis de este estudio se realizaron utilizando el programa estadístico SPSS versión 29.0.1.0 (171).

## 2.5. Consideraciones éticas

Se obtuvo el consentimiento informado de todos los participantes, y se garantizó la confidencialidad de los datos recopilados. El estudio fue aprobado por el comité de ética de la institución correspondiente.

## 2.6. Limitaciones y justificación del tamaño muestral

Reconocemos que el tamaño de la muestra puede limitar la generalización de los resultados. Sin embargo, como estudio piloto, esta investigación proporciona una base sólida para validar el modelo AETGE y sus constructos, permitiendo refinamientos antes de una implementación a mayor escala. Según Johanson y Brooks (2010), para estudios piloto en desarrollo de escalas, una muestra de 30 puede ser suficiente para estimaciones preliminares. Nuestra muestra de 87 participantes supera este umbral, ofreciendo mayor robustez a nuestros hallazgos iniciales.

## 3. Resultados

Este estudio analizó ocho variables relacionadas con la adopción de la Inteligencia Artificial Generativa (IAG) en la educación superior. La Tabla 3 presenta los estadísticos descriptivos de estas variables.

**Tabla 3.**

*Estadísticos descriptivos de las variables del estudio*

Nombre de la variable	Media	Mediana	Desv.Stan	Min	Máx
Percepción de utilidad	3.26	3.25	0.695	1	5
Percepción facilidad uso	3.18	3.25	0.389	2	4
Valor percibido	3.14	3.25	0.738	2	5
Expectativa de rendimiento	2.70	3	0.844	1	5
Influencia social	2.29	2.50	0.813	1	4
Condiciones facilitadoras	2.17	2	0.791	1	4
Expectativas	3.50	3.50	0.918	1	5
Preocupaciones	3.80	4	0.890	2	5

**Fuente:** Elaboración propia (2024)

Como se puede observar, las variables Expectativa de rendimiento, Influencia social, Condiciones facilitadoras y Expectativas muestran una mayor variabilidad en las respuestas (desviaciones estándar  $> 0.8$ ). Las variables Percepción de utilidad y Percepción de facilidad de uso presentan una menor dispersión (desviaciones estándar  $< 0.7$ ), indicando una mayor consistencia en las respuestas. Respecto a los valores mínimos y máximos, la información proporcionada en la tabla 3 indica que las variables Percepción de facilidad de uso, Valor

percibido y Preocupaciones no registraron respuestas en el valor mínimo de la escala. De la misma manera las variables Influencia social, Condiciones facilitadoras y Percepción de facilidad de uso no alcanzaron el valor máximo en ninguna respuesta.

En este estudio, para el análisis de comparación de muestras independientes, tomando como subgrupos los hombres y las mujeres que componen la muestra, se ha utilizado la t-Student.

La tabla 4 muestra la media de la muestra por género para cada variable.

**Tabla 4.**

*Comparación de medias por género*

Nombre de la variable	Media	
	Hombres (n=44)	Mujeres(n=43)
Percepción de utilidad	3.31	3.22
Percepción facilidad uso	3.13	3.22
Valor percibido	3.16	3.13
Expectativa de rendimiento	2.70	2.70
Influencia social	2.12	2.45
Condiciones facilitadoras	1.98	2.35
Expectativas	3.28	3.72
Preocupaciones	3.64	3.97

Fuente: Elaboración propia (2024)

En la tabla 5 se puede ver los resultados de las pruebas de muestras independientes con t-Student. Como se puede observar no se encontraron diferencias significativas entre hombres y mujeres en las variables Percepción de utilidad, Percepción de facilidad de uso, Valor percibido y Expectativa de rendimiento ( $p > 0.05$ ).

**Tabla 5.**

*Prueba de muestras independientes.*

		t	gl	Significación		Diferencia de medias	Diferencia de error estándar
				P de un factor	P de dos factores		
Percepción de utilidad	Asume var.iguales	,578	85	,282	,564	,087	,150
	No asume var.iguales	,576	74,357	,283	,566	,087	,150
Percepción de facilidad de uso	Asume var.iguales	-,985	85	,164	,327	-,082	,083
	No asume var.iguales	-,982	77,858	,165	,329	-,082	,084
Valor percibido	Asume var.iguales	,238	85	,406	,813	,038	,159
	No asume var.iguales	,237	84,638	,406	,813	,038	,159
Expectativa de rendimiento	Asumen var.iguales	-,038	85	,485	,970	-,007	,182
	No asume var.iguales	-,038	81,849	,485	,970	-,007	,182

Influencia social	Asumen var. iguales	-1,973	85	,026	,052	-,338	,171
	No asumen var. iguales	-1,972	84,444	,026	,052	-,338	,172
Condiciones facilitadoras	Asumen var. iguales	-2,266	85	,013	,026*	-,376	,166
	No asumen var. iguales	-2,266	84,873	,013	,026*	-,376	,166
Expectativas	Se asumen var. iguales	-2,272	85	,013	,026*	-,437	,192
	No asumen var. iguales	-2,266	80,440	,013	,026*	-,437	,193
P	Asumen var. iguales	-1,729	85	,044	,087	-,326	,189
	No asumen var. iguales	-1,722	73,869	,045	,089	-,326	,190

\*p < 0.05

Fuente: Elaboración propia (2024).

La variable Influencia social mostró una diferencia marginalmente significativa entre géneros ( $p = 0.052$ ), con las mujeres mostrando una mayor influencia social ( $M = 2.45$ ) que los hombres ( $M = 2.12$ ). Además, se observaron diferencias significativas en las variables Condiciones facilitadoras y Expectativas ( $p < 0.05$ ). Respecto a las Condiciones facilitadoras, las mujeres perciben mayores condiciones facilitadoras ( $M = 2.35$ ) que los hombres ( $M = 1.98$ ). Asimismo, las mujeres muestran Expectativas más altas ( $M = 3.72$ ) que los hombres ( $M = 3.28$ ). Finalmente, la variable Preocupaciones mostró una diferencia no significativa pero cercana al umbral ( $p = 0.087$ ), con las mujeres expresando ligeramente más preocupaciones ( $M = 3.97$ ) que los hombres ( $M = 3.64$ ).

## 4. Discusión

Los resultados de este estudio proporcionan valiosas perspectivas sobre la percepción y adopción de la Inteligencia Artificial Generativa (IAG) en la educación superior. Los hallazgos revelan que la percepción de utilidad, facilidad de uso y valor percibido de la IAG entre los docentes es moderadamente alta, sin diferencias significativas entre géneros. La mediana del valor percibido (3.25) sugiere una inclinación ligeramente positiva hacia el valor añadido de la IAG en la labor docente, lo cual es consistente con los hallazgos de Kim *et al.* (2007) sobre la importancia del valor percibido en la adopción de tecnologías educativas.

Estos resultados concuerdan con la literatura reciente sobre adopción de tecnologías emergentes en educación superior. Ifenthaler y Schumacher (2023) destacan la importancia de la percepción positiva de utilidad y facilidad de uso para la adopción de IA en educación. Sorprendentemente, los docentes muestran expectativas moderadas sobre el rendimiento de la IAG, con opiniones variadas. Dwivedi *et al.* (2019) atribuyen esta discrepancia a la novedad tecnológica y falta de experiencia práctica. Zhang y Aslan (2021) sugieren que la escasez de ejemplos exitosos en contextos educativos específicos influye en las expectativas de rendimiento, evidenciando la necesidad de más investigación y casos de estudio.



Los resultados indican una influencia social de baja a moderada en la adopción de la IAG, con diferencias entre géneros, estando las mujeres más influenciadas que los hombres. La percepción de condiciones facilitadoras es generalmente baja, con diferencias significativas entre géneros. Ellos consideran que este apoyo es mucho menor que lo que consideran las mujeres y aunque hay una alta diversidad de respuestas, ningún participante en este estudio percibe las condiciones facilitadoras como excelentes. Estos hallazgos subrayan la importancia del apoyo institucional en la adopción de nuevas tecnologías, como señalan Dwivedi *et al.* (2019). Zawacki-Richter *et al.* (2019) enfatizan que el apoyo institucional y la creación de un entorno propicio son fundamentales para la adopción exitosa de tecnologías de IA en educación superior. La diferencia de género observada en la influencia social podría reflejar diferentes patrones de interacción y colaboración entre docentes, un aspecto que merece mayor investigación.

Las altas expectativas y preocupaciones observadas, especialmente entre las mujeres, son consistentes con la literatura sobre adopción de tecnologías educativas (Scherer *et al.*, 2019). La preocupación ética significativa (media de 3.53 en el ítem específico) refleja los desafíos planteados por Lee y Yoon (2017) sobre la implementación ética de la IA en educación. Estas preocupaciones éticas se alinean con los hallazgos de Hemachandran *et al.* (2022), quienes destacan la necesidad de abordar cuestiones como la privacidad de los datos y la equidad en el uso de sistemas de IA en educación. La alta puntuación en preocupaciones subraya la importancia de desarrollar marcos éticos robustos para la implementación de IAG en entornos educativos.

Los resultados sugieren que, aunque existe una percepción moderadamente positiva de la IAG, hay barreras significativas para su adopción plena, incluyendo bajas expectativas de rendimiento y preocupaciones éticas. Esto resalta la necesidad de estrategias de implementación que aborden estas preocupaciones y mejoren las condiciones facilitadoras, como proponen Teo (2011) y Cheng (2019). La variabilidad en las respuestas indica que la adopción de la IAG en educación superior no es un proceso homogéneo, sino que está influenciado por factores individuales e institucionales. Esto concuerda con el modelo UTAUT de Venkatesh *et al.* (2003) y sugiere la necesidad de enfoques personalizados en la introducción de la IAG en entornos educativos.

## 5. Conclusiones

Este trabajo combina los modelos TAM, VAM y UTAUT para analizar la percepción y uso de IAG entre el Personal Docente e Investigador de universidades españolas. Los resultados revelan una aceptación moderada de la IAG. Los componentes del TAM (utilidad y facilidad de uso percibidas) y del VAM (valor percibido) indican una intención de uso moderada, sugiriendo potencial de adopción con cierta cautela. Esto coincide con Scherer *et al.* (2019) sobre la adopción gradual de nuevas tecnologías en educación.

Sin embargo, el análisis basado en el modelo UTAUT revela barreras significativas para la adopción generalizada. La expectativa de rendimiento, la influencia social y las condiciones facilitadoras no alcanzan niveles óptimos. Particularmente, se evidencia una falta significativa de condiciones facilitadoras y apoyo institucional, lo cual concuerda con los hallazgos de Dwivedi *et al.* (2019) sobre la importancia del respaldo organizacional en la adopción de tecnologías emergentes.

Un aspecto interesante es la coexistencia de entusiasmo y preocupaciones éticas. Se observa un interés generalizado en la formación para el uso de IAG, contrastado con preocupaciones éticas significativas. Esta dualidad refleja las observaciones de Lee y Yoon (2017) sobre la

necesidad de abordar cuestiones éticas en la implementación de IA en educación. Además, el estudio revela diferencias de género en aspectos como la influencia social y las expectativas, lo cual merece una exploración más profunda en futuras investigaciones, como sugieren Venkatesh *et al.* (2003) en su trabajo sobre la aceptación de tecnologías.

Esta investigación contribuye significativamente al entendimiento de la adopción de IAG en entornos académicos, ofreciendo implicaciones valiosas para la política educativa, el desarrollo tecnológico y la práctica docente. Destaca la necesidad de desarrollar estrategias institucionales que fomenten la adopción de IAG, abordando las preocupaciones éticas y mejorando las condiciones facilitadoras. Además, proporciona perspectivas valiosas para los desarrolladores de IAG sobre las necesidades y preocupaciones específicas del sector educativo, y subraya la importancia de la formación y el apoyo continuo para facilitar la integración efectiva de la IAG en la enseñanza universitaria.

No obstante, es importante reconocer las limitaciones del estudio. El tamaño limitado de la muestra puede no representar completamente la diversidad del personal docente e investigador. Además, la baja fiabilidad del constructo de Influencia Social en el modelo UTAUT sugiere la necesidad de refinar su medición en futuras investigaciones. La naturaleza transversal del estudio también limita la comprensión de cómo evolucionan las percepciones y la adopción de IAG a lo largo del tiempo.

En futuras líneas de investigación se podrían abordar estas limitaciones mediante estudios con muestras más amplias y diversas, análisis por universidades, y diseños longitudinales. También sería valioso explorar cómo factores como el género, la categoría profesional o la institución moderan los resultados. Además, se requiere una investigación más profunda sobre las preocupaciones éticas específicas y cómo abordarlas efectivamente en el contexto universitario.

En resumen, este estudio ofrece una comprensión profunda de la adopción de IAG en la educación superior española, resaltando oportunidades y desafíos. Los resultados enfatizan la necesidad de un enfoque integral que aborde cuestiones éticas, mejore las condiciones facilitadoras y fomente la innovación tecnológica. Proporciona orientación valiosa para investigadores, administradores y responsables de políticas educativas en la implementación efectiva y responsable de IAG en entornos académicos.

## 6. Referencias

- Ajzen, I. (1991). The theory of planned behavior. *Organizational Behavior and Human Decision Processes*, 50(2), 179-211. [https://doi.org/10.1016/0749-5978\(91\)90020-T](https://doi.org/10.1016/0749-5978(91)90020-T)
- Anusha, L. y Nagaraja, G. S. (2021). Outlier Detection in High Dimensional Data. *International Journal of Engineering and Advanced Technology*, 10(5), 128-130. <https://doi.org/10.35940/ijeat.E2675.0610521>
- Baker, R. S. (2016). Stupid Tutoring Systems, Intelligent Humans. *International Journal of Artificial Intelligence in Education*, 26(2), 600-614. <https://acortar.link/WDPvIH>
- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D. M., Wu, J., Winter, C., Hesse, C., Chen, M., Sigler, E., Litwin, M., Gray, S., Chess, B., Clark, J., Berner, C., McCandlish, S., Radford, A., Sutskever, I. y Amodei, D. (2020). Language models are few-shot learners. *Advances in*

*Neural Information Processing Systems*, 33, 1877-1901.  
<https://doi.org/10.48550/arXiv.2005.14165>

- Bryson, J. J. (2018). La última década y el futuro del impacto de la IA en la sociedad. En BBVA (Ed.), *¿Hacia una nueva Ilustración? Una década trascendente* (pp. 127-159). Turner.
- Bryson, J. J. y Winfield, A. F. T. (2017). Standardizing ethical design for artificial intelligence and autonomous systems. *Computer*, 50(5), 116-119.  
<https://doi.org/10.1109/MC.2017.154>
- Bryson, J. J. y Theodorou, A. (2019). How society can maintain human-centric artificial intelligence. In M. Toivonen y E. Saari (Eds.), *Human-centered digitalization and services* (pp. 305-323). Springer. [https://doi.org/10.1007/978-981-13-7725-9\\_16](https://doi.org/10.1007/978-981-13-7725-9_16)
- Bryson, J. J., Diamantis, M. E. y Grant, T. D. (2017). Of, for, and by the people: the legal lacuna of synthetic persons. *Artificial Intelligence and Law*, 25(3), 273-291.  
<https://doi.org/10.1007/s10506-017-9214-9>
- Bryson, J. J. (2015). Artificial Intelligence and Pro-Social Behaviour. En C. Misselhorn (Ed.), *Collective Agency and Cooperation in Natural and Artificial Systems. Philosophical Studies Series* (pp. 305-323). Springer, Cham. [https://doi.org/10.1007/978-3-319-15515-9\\_15](https://doi.org/10.1007/978-3-319-15515-9_15)
- Cheng, E. W. (2019). Choosing between the theory of planned behavior (TPB) and the technology acceptance model (TAM). *Educational Technology Research and Development*, 67(1), 21-37. <https://doi.org/10.1007/s11423-018-9598-6>
- Cheng, Y. M. (2019). How does task-technology fit influence cloud-based e-learning continuance and impact? *Education + Training*, 61(4), 480-499.  
<https://doi.org/10.1108/ET-09-2018-0203>
- Dans, E. (11 de julio de 2024). China y el interesantísimo proceso de adopción de la inteligencia artificial generativa. Enrique Dans Blog. <https://bit.ly/3W0ABIB>
- 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>
- Devlin, J., Chang, M. W., Lee, K. y Toutanova, K. (2018). Bert: Pre-training of deep bidirectional transformers for language understanding. arXiv preprint arXiv:1810.04805.  
<https://doi.org/10.48550/arXiv.1810.04805>
- Dwivedi, Y. K., Rana, N. P., Jeyaraj, A., Clement, M. y Williams, M. D. (2019). Re-examining the unified theory of acceptance and use of technology (UTAUT): Towards a revised theoretical model. *Information Systems Frontiers*, 21(3), 719-734.  
<https://doi.org/10.1007/s10796-017-9774-y>
- Gasimova, C. (2023). Privacy and Transparency in an AI-driven World: Does Algorithmic Transparency Fit on Data Privacy Under GDPR? *SSRN Electronic Journal*.  
<https://doi.org/10.2139/ssrn.1234567>

- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. y Bengio, Y. (2014). Generative adversarial nets. *Advances in neural information processing systems*, 27, 1-9. <https://doi.org/10.48550/arXiv.1406.2661>
- Goodman, B. y Flaxman, S. (2016). EU regulations on algorithmic decision-making and a "right to explanation". En B. Kim, D. M. Malioutov y K. R. Varshney (Eds.), *Proceedings of the ICML Workshop on Human Interpretability in Machine Learning (WHI 2016)* (pp. 26-30). arXiv. <https://doi.org/10.48550/arXiv.1606.08813>
- Hair, J. F., Black, W. C., Babin, B. J. y Anderson, R. E. (2010). *Multivariate data analysis (7th ed.)*. Pearson.
- Hemachandran, K., Verma, P., Pareek, P., Arora, N., Rajesh Kumar, K. V., Ahanger, T. A., Audumbar Pise, A. y Ratna, R. (2022). Artificial intelligence: A universal virtual tool to augment tutoring in higher education. *Computational Intelligence and Neuroscience*, 2022(1), 1410448. <https://doi.org/10.1155/2022/1410448>
- Hochreiter, S. y Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Humphry, T. y Fuller, A. L. (2023). Potential ChatGPT use in undergraduate chemistry laboratories. *Journal of Chemical Education*, 100(4), 1434-1436. <https://doi.org/10.1021/acs.jchemed.2c0123>
- Ifenthaler, D. y Schumacher, C. (2023). Reciprocal issues of artificial and human intelligence in education. *Journal of Research on Technology in Education*, 55(1), 1-6. <https://doi.org/10.1080/15391523.2022.2040086>
- Irfan, M., Aldulaylan, F. y Alqahtani, Y. (2023). Ethics and Privacy in Irish Higher Education: A Comprehensive Study of Artificial Intelligence (AI) Tools Implementation at University of Limerick. *Global Social Sciences Review*, VIII(II), 201-210. [https://doi.org/10.31703/gssr.2023\(VIII-II\).22](https://doi.org/10.31703/gssr.2023(VIII-II).22)
- Johanson, G. A. y Brooks, G. P. (2010). Initial scale development: Sample size for pilot studies. *Educational and Psychological Measurement*, 70(3), 394-400. <https://doi.org/10.1177/0013164409355692>
- Kadaruddin. (2023). Empowering Education through Generative AI: Innovative Instructional Strategies for Tomorrow's Learners. *International Journal of Business, Law, and Education*, 4(2), 618-625. <https://doi.org/10.56442/ijble.v4i2.215>
- Kim, H. W., Chan, H. C. y Gupta, S. (2007). Value-based adoption of mobile internet: an empirical investigation. *Decision Support Systems*, 43(1), 111-126. <https://doi.org/10.1016/j.dss.2005.05.009>
- Lee, I. y Yoon, Y. J. (2017). Ethical issues and concerns in artificial intelligence in education. *Journal of Intelligence Systems*, 27(3), 355-370. <https://doi.org/10.1515/jisys-2017-0033>
- Lee, J. G. y Yoon, W. (2017). Big Data Meets Artificial Intelligence: Challenges and Opportunities. *Journal of Big Data*, 4(1), 12-23. <https://acortar.link/uhq1bR>

- Limayem, M., Hirt, S. G. y Cheung, C. M. (2007). How habit limits the predictive power of intention: The case of information systems continuance. *MIS Quarterly*, 31(4), 705-737. <https://doi.org/10.2307/25148817>
- Márquez, R., Barrios, N., Vera, R. E., Mendez, M. E., Tolosa, L., Zambrano, F. y Li, Y. (2023). A perspective on the synergistic potential of artificial intelligence and product-based learning strategies in biobased materials education. *Education for Chemical Engineers*, 44, 164-180. <https://doi.org/10.1016/j.ece.2023.05.005>
- McKinsey & Company. (2024). The state of AI in 2024: Adoption and value creation across industries. *McKinsey Global Institute*. <https://11nq.com/liBlw>
- National Geographic España. (2020). Breve historia visual de la inteligencia artificial. <https://bit.ly/3WosQgY>
- Ongsulee, P. (2017). Artificial Intelligence, Machine Learning and Deep Learning. 2017 Fifteenth International Conference on ICT and Knowledge Engineering, 1-6. <https://doi.org/10.1109/ICTKE.2017.8259629>
- OpenAI. (2023). GPT-4 Technical Report. arXiv preprint arXiv:2303.08774. <https://doi.org/10.48550/arXiv.2303.08774>
- Pareto. (s.f.). Historia de la inteligencia artificial: del origen al futuro de la tecnología. *Pareto Blog*. <https://blog.pareto.io/es/historia-de-la-inteligencia-artificial/>
- Petty, R. E. y Cacioppo, J. T. (1986). The elaboration likelihood model of persuasion. *Advances in Experimental Social Psychology*, 19, 123-205. <https://acortar.link/F0Q3Ks>
- Radford, A., Narasimhan, K., Salimans, T. y Sutskever, I. (2018). Improving language understanding by generative pre-training. arXiv preprint arXiv:1810.04805. <https://doi.org/10.48550/arXiv.1810.04805>
- Radford, A., Wu, J., Child, R., Luan, D., Amodei, D. y Sutskever, I. (2019). Language models are unsupervised multitask learners. *OpenAI blog*, 1(8), 9. <https://bit.ly/3WosQgY>
- Raghupathi, W. y Raghupathi, V. (2014). Big Data Analytics in Healthcare: Promise and Potential. *Health Information Science and Systems*, 2(3), 1-10. <https://doi.org/10.1186/2047-2501-2-3>
- Sánchez-Ruiz, L. M., Moll-López, S., Nuñez-Pérez, A., Moraño-Fernández, J. A. y Vega-Fleitas, E. (2023). ChatGPT challenges blended learning methodologies in engineering education: A case study in mathematics. *Applied Sciences*, 13(10), 6039. <https://doi.org/10.3390/app13106039>
- Scherer, R., Siddiq, F. y Tondeur, J. (2019). The technology acceptance model (TAM): A meta-analytic structural equation modeling approach to explaining teachers' adoption of digital technology in education. *Computers & Education*, 128, 13-35. <https://doi.org/10.1016/j.compedu.2018.09.009>
- Stewart, A. J., McCarty, N. y Bryson, J. J. (2018). Explaining parochialism: A causal account for political polarization in changing economic environments. arXiv. <https://doi.org/10.1126/sciadv.abd4201>



- Taylor, S. y Todd, P. A. (1995). Understanding information technology usage: A test of competing models. *Information Systems Research*, 6(2), 144-176. <https://doi.org/10.1287/isre.6.2.144>
- Teo, T. (2011). Factors influencing teachers' intention to use technology: Model development and test. *Computers & Education*, 57(4), 2432-2440. <https://doi.org/10.1016/j.compedu.2011.06.008>
- Thoppilan, R., De Freitas, D., Hall, J., Shazeer, N., Kulshreshtha, A., Cheng, H. T., Jin, A., Bos, T., Baker, L., Du, Y., Li, Y., Lee, H., Zheng, H. S., Ghafouri, A., Menegali, M., Huang, Y., Krikun, M., Lepikhin, D., Qin, J., Chen, D., Xu, Y., Chen, Z., Roberts, A., Bosma, M., Zhao, V., Zhou, Y., Chang, C. C., Krivokon I., Rusch, W., Pickett, M., Srinivasan, P., Man, L., Meier-Hellstern, K., Ringel Morris, M., Doshi, T., Delos Santos, R., Duke, T., Soraker, J., Zevenbergen, B., Prabhakaran, V., Diaz, M., Hutchinson, B., Olson, K., Molina, A., Hoffman-John, E., Lee, J., Aroyo, L., Rajakumar, R., Butryna, A., Lamm, M., Kuzmina, V., Fenton, J., Cohen, A., Bernstein, R., Kurzweil, R., Aguera-Arcas, B., Cui, C., Croak, M., Chi, E. y Le, Q. (2022). *LaMDA: Language models for dialog applications*. arXiv preprint arXiv:2201.08239. <https://doi.org/10.48550/arXiv.2201.08239>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gómez, A. N., Kaiser, Ł. y Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30. <https://doi.org/10.48550/arXiv.1706.03762>
- Venkatesh, V., Morris, M. G., 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>
- Whittaker, M., Crawford, K., Dobbe, R., Fried, G., Kaziunas, L., Mathur, V., West, S. M. y Zevenbergen, B. (2023). AI and ethics: A review of global initiatives. *Journal of Ethical AI*, 5(2), 112-136. <https://doi.org/10.1007/s40593-016-0105-0>
- Yeralan, S. y Lee, L. (2023). Generative AI: Challenges to higher education. *Sustainable Engineering and Innovation*. <https://doi.org/10.37868/sei.v5i2.id196>
- Zawacki-Richter, O., Marín, V. I., Bond, M. y Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education - where are the educators? *International Journal of Educational Technology in Higher Education*, 16(1), 39. <https://doi.org/10.1186/s41239-019-0171-0>
- Zhai, X., Chu, X., Chai, C., Jong, M., Istenič, A., Spector, M., Liu, J., Yuan, J. y Li, Y. (2021). A Review of Artificial Intelligence (AI) in Education from 2010 to 2020. *Complexity*, 2021, 8812542. <https://doi.org/10.1155/2021/8812542>
- Zhang, J., Gao, M., Holmes, W., Mavrikis, M. y Ma, N. (2021). Interaction patterns in exploratory learning environments for mathematics: A sequential analysis of feedback and external representations in Chinese schools. *Interactive Learning Environments*, 29(7), 1211-1228. <https://doi.org/10.1080/10494820.2019.1620290>

- Zhang, K. y Aslan, A. B. (2021). AI technologies for education: Recent research & future directions. *Computers and Education: Artificial Intelligence*, 2, 100025. <https://doi.org/10.1016/j.caeai.2021.100025>
- Zhu, Y., Wang, V. L., Wang, Y. A. y Nastos, J. (2018). The relationship between instructors' technology readiness and their intention to use e-learning systems: A case of a technical college in Taiwan. *International Journal of E-Learning & Distance Education*, 33(1), 1-18. <https://doi.org/10.1108/INTR-01-2018-0043>
- Zohny, H., McMillan, J. y King, M. (2023). Ethics of generative AI. *Journal of Medical Ethics*, 49(2), 79-80. <https://doi.org/10.1136/medethics-2022-108079>

**AUTORES:****Juana María Padilla Piernas**

Universidad Católica de Murcia, España.

Profesora de ADE en la UCAM, doctora en Ciencias Sociales. Licenciada en Publicidad y Relaciones Públicas, diplomada en C. Empresariales. Máster en Dirección de Empresas y Marketing, y en Dirección Hotelera. Especializada en redes sociales, comportamiento del consumidor, marketing digital y turístico. Ha presentado investigaciones en congresos nacionales e internacionales. Coautora de artículos en revistas académicas como International Journal of Scientific Management and Tourism, IJST, y "Digital and Social Media Marketing" (Springer), RIED., Cuadernos de Turismo entre otros.

[jmpadilla@ucam.edu](mailto:jmpadilla@ucam.edu)

**Orcid:** <https://orcid.org/0000-0002-6075-3114>

**Google Scholar:** <https://scholar.google.com/citations?user=QfLK9awAAAAJ&hl=es>

**María del Mar Martín García**

Universidad Isabel I, España.

Doctora en C. Económicas y Empresariales por la Universidad de Almería, con mención internacional. Investiga en comportamiento del consumidor, turismo deportivo y gestión turística. Ha publicado en revistas como Healthcare y PASOS, abordando temas como turismo de golf, salud deportiva y marketing digital. Contribuye con capítulos en libros sobre turismo deportivo y marketing en redes sociales. Su investigación incluye análisis bibliométricos del golf y salud, estudios sobre imagen del golf e impacto de eventos deportivos en turismo. Colabora frecuentemente en publicaciones académicas y libros especializados en turismo y marketing.

[mariadelmar.martin.garcia@ui1.es](mailto:mariadelmar.martin.garcia@ui1.es)

**Orcid:** <https://orcid.org/0000-0002-1824-7023>