



José Gabriel Rodríguez-Rivas

E-mail: gabriel.rodriguez@itdurango.edu.mx

Orcid: <https://orcid.org/0000-0002-7031-5097>

Fernando Ayala-Partida

E-mail: fayala@itdurango.edu.mx

Orcid: <https://orcid.org/0009-0001-0024-1053>

Luis Campa-Galindo

E-mail: lcampa@itdurango.edu.mx

Orcid: <https://orcid.org/0009-0003-6286-2079>

Tecnológico Nacional de México / Instituto Tecnológico de Durango. México

Cita sugerida (APA, séptima edición)

Rodríguez-Rivas, J. G., Ayala-Partida, F., & Campa-Galindo, L. (2026). Aceptación de la inteligencia artificial generativa en docentes: adaptación y validación de un instrumento basado en el TAM. *Revista Portal de la Ciencia*, 7(2), 217-232, DOI: <https://doi.org/10.51247/pdlc.v7i2.766>.

==== o ====

Aceptación de la inteligencia artificial generativa en docentes: adaptación y validación de un instrumento basado en el TAM

RESUMEN

La inteligencia artificial generativa (IAG) representa una herramienta disruptiva en la educación superior, con un alto potencial para transformar la enseñanza, la investigación y la gestión académica. El objetivo de este estudio fue adaptar y validar un instrumento confiable y válido que permitiera evaluar la aceptación y el uso de la IAG en docentes de educación superior, con base en el Modelo de Aceptación Tecnológica (TAM). Se realizó un estudio cuantitativo, no experimental y transversal, con enfoque instrumental, en el que participaron 100 docentes. El instrumento, denominado Escala de Aceptación y Uso de la Inteligencia Artificial Generativa (EAU-IAG), fue sometido a análisis factorial exploratorio y confirmatorio. Los resultados del AFE identificaron una estructura de cuatro factores coherente con el TAM, que explicó el 63.96% de la varianza total. El AFC corroboró la validez factorial del modelo, mostrando cargas factoriales estandarizadas adecuadas y estadísticamente significativas, así como índices de ajuste global satisfactorios (CFI = 0.969, TLI = 0.964, RMSEA = 0.039). Asimismo, los coeficientes de confiabilidad evidenciaron alta consistencia interna por dimensión. Los hallazgos respaldan el uso de la EAU-IAG como una herramienta válida y confiable para estudios diagnósticos e investigaciones futuras sobre la adopción de la IAG en contextos de educación superior.

Palabras clave: Inteligencia artificial generativa, educación superior, docentes, Modelo de Aceptación Tecnológica, validación de instrumentos

Acceptance of generative artificial intelligence among teachers: adaptation and validation of an instrument based on the TAM

ABSTRACT

Generative artificial intelligence (GAI) represents a disruptive tool in higher education, with significant potential to transform teaching, research, and academic management. The objective of this study was to adapt and validate a reliable and valid instrument to assess the acceptance and use of GAI among higher education faculty, based on the Technology Acceptance Model (TAM). A quantitative, non-experimental, cross-sectional study with an instrumental approach was conducted with a sample of 100 faculty members. The instrument, called the Generative Artificial Intelligence Acceptance and Use Scale (EAU-IAG), was subjected to exploratory and confirmatory factor analyses. The EFA identified a four-factor structure consistent with the TAM, explaining 63.96% of the total variance. The CFA confirmed the factorial validity of the proposed model, showing adequate and statistically significant standardized factor loadings, as well as satisfactory global fit indices (CFI = 0.969, TLI = 0.964, RMSEA = 0.039). In addition, reliability coefficients indicated high internal consistency across dimensions. These findings support the use of the EAU-IAG as a valid and reliable instrument for diagnostic studies and future research on the adoption of GAI in higher education contexts.

Keywords: Generative artificial intelligence, higher education, faculty, Technology Acceptance Model, instrument validation.

==== o ====

Aceitação da inteligência artificial generativa entre professores: adaptação e validação de um instrumento baseado no TAM.

RESUMO

A inteligência artificial generativa (IAG) representa uma ferramenta disruptiva no ensino superior, com alto potencial para transformar o ensino, a pesquisa e a gestão acadêmica. O objetivo deste estudo foi adaptar e validar um instrumento confiável e válido para avaliar a aceitação e o uso da IAG entre docentes do ensino superior, com base no Modelo de Aceitação da Tecnologia (TAM). Um estudo quantitativo, não experimental e transversal, com abordagem instrumental, foi conduzido com 100 docentes. O instrumento, denominado Escala de Aceitação e Uso da Inteligência Artificial Generativa (EAU-GAI), foi submetido a análises fatoriais exploratória e confirmatória. Os resultados da AFE identificaram uma estrutura de quatro fatores consistente com o TAM, que explicou 63,96% da variância total. A análise fatorial confirmatória (AFC) corroborou a validade fatorial do modelo, apresentando cargas fatoriais padronizadas adequadas e estatisticamente significativas, bem como índices de ajuste geral satisfatórios (CFI = 0,969, TLI = 0,964, RMSEA = 0,039). Além disso, os coeficientes de confiabilidade demonstraram alta consistência interna por dimensão. Esses resultados corroboram o uso do EAU-IAG como uma ferramenta válida e confiável para estudos diagnósticos e pesquisas futuras sobre a adoção de IAG em contextos de ensino superior.

Palavras-chave: Inteligência artificial generativa, ensino superior, corpo docente, Modelo de Aceitação da Tecnologia, validação de instrumentos

==== o ====

INTRODUCCIÓN

La transformación digital en la educación superior ha generado un cambio profundo en los enfoques pedagógicos, impulsando la integración de tecnologías digitales como herramientas clave para mejorar los procesos de enseñanza-aprendizaje. Esta evolución no solo responde

a la necesidad de modernizar las prácticas docentes, sino también a la urgencia de preparar a los estudiantes para entornos altamente digitalizados. La incorporación de tecnologías de la información y la comunicación (TIC) en el aula ha demostrado ser un factor determinante para fortalecer las competencias digitales del profesorado y fomentar experiencias educativas más dinámicas e inclusivas (Santiago-Trujillo y Garvich-Ormeño, 2024).

Además, la digitalización educativa requiere una planificación estratégica que considere tanto la infraestructura tecnológica como la capacitación docente, elementos esenciales para lograr una transformación efectiva y sostenible en las instituciones de educación superior (Timotheou et al., 2023).

En este contexto, la incorporación de la inteligencia artificial generativa (IAG) en el ámbito educativo ha revolucionado la manera en que docentes y estudiantes interactúan con el conocimiento, planteando nuevas oportunidades y retos para la educación. La IAG, definida como sistemas de inteligencia artificial capaces de crear contenido original como texto, imágenes, código, y más a partir de datos y patrones aprendidos (Kalota, 2024), ha emergido como una herramienta disruptiva que puede transformar procesos académicos, investigativos y administrativos en las universidades.

En particular, los docentes de educación superior se encuentran en una posición estratégica para aprovechar las capacidades de estas tecnologías con el fin de potenciar su labor educativa e investigativa. La IAG permite adaptar el contenido educativo a las necesidades de los estudiantes, creando experiencias de aprendizaje más dinámicas y efectivas. Su capacidad para generar contenido personalizado y dinámico permite a los docentes adaptar materiales educativos a sus necesidades, optimizando el proceso de aprendizaje (Alier et al., 2024).

En los últimos años, diversas herramientas de IAG, como ChatGPT, Copilot, Gemini, DeepSeek y Grok, han comenzado a utilizarse ampliamente en contextos académicos y educativos. Investigaciones recientes han analizado incluso la calidad de las respuestas generadas por estas herramientas en tareas específicas, evidenciando diferencias significativas en aspectos como la solidez técnica de las respuestas y la capacidad de proporcionar ejemplos aplicados (Pizarro et al., 2025).

Sin embargo, el uso de la IAG por parte de los docentes no está exento de desafíos. Aspectos como la confiabilidad de la información generada, la ética en el uso de estas tecnologías, la necesidad de formación especializada y la integración pedagógica adecuada, son puntos críticos que requieren atención para garantizar una adopción responsable y efectiva (Gallent-Torres et al., 2023). Además, la percepción que los docentes tengan sobre la utilidad y facilidad de uso influye directamente en su disposición para incorporar estas herramientas en su práctica profesional (Venkatesh et al., 2003).

En este sentido, el Modelo de Aceptación Tecnológica (TAM) propuesto por Davis (1989), se ha consolidado como un marco teórico robusto y ampliamente utilizado para comprender y predecir la adopción de nuevas tecnologías en diversos contextos organizacionales, incluyendo la educación (Venkatesh y Bala, 2008).

El TAM ha sido utilizado para explicar la intención de uso de nuevas tecnologías a partir de dos dimensiones fundamentales: la utilidad percibida y la facilidad de uso percibida. La utilidad percibida se refiere al grado en que una persona cree que el uso de una tecnología mejorará su desempeño, mientras que la facilidad de uso percibida alude a la medida en que el usuario considera que la tecnología será libre de esfuerzo (Davis y Granić, 2024). Estas dimensiones influyen directamente en la actitud hacia el uso y, en consecuencia, en la intención de uso, lo que convierte al TAM en un modelo robusto para predecir la aceptación tecnológica en diversos contextos, incluyendo la educación, la salud y los entornos empresariales (Evayani et al., 2024).

Además, estos constructos permiten no solo medir el grado de aceptación sino también identificar barreras y facilitadores para la adopción efectiva de la IAG en entornos académicos, contribuyendo así a un diseño pedagógico más informado y adaptado a las necesidades reales de los docentes (Teo, 2011).

El TAM ha sido ampliamente validado y adaptado en distintos contextos, incluyendo la educación superior, la salud, la industria y entornos organizacionales (Venkatesh y Davis, 2000; King y He, 2006). Por ejemplo, ha sido modificado para analizar la adopción de tecnologías basadas en inteligencia artificial dentro del sector de la construcción (Na et al., 2022), para valorar la incorporación de dispositivos inteligentes en los hogares como parte de sistemas de automatización doméstica (Shin et al., 2018). Asimismo, se ha empleado para evaluar la adopción de plataformas de aprendizaje en línea por parte de estudiantes durante la crisis sanitaria provocada por COVID-19 (Prasetyo et al., 2021).

En esta misma línea, Teo (2011) adaptó el modelo para evaluar la intención de uso de tecnologías educativas por parte de docentes, destacando la necesidad de contextualizar los ítems de acuerdo con las características del entorno educativo. Igualmente, Al-Rahmi et al. (2019) realizaron una adaptación del TAM y la teoría de motivación para evaluar la adopción del Big Data y el intercambio de gestión del conocimiento en el ámbito educativo (OECD, 2021).

Por otra parte, el desarrollo de instrumentos confiables y válidos alineados con el TAM tiene un impacto relevante para las políticas educativas y la formación docente en IA, tal como lo promueven organismos internacionales como la UNESCO, que resaltan la necesidad de fortalecer las competencias digitales y la integración ética de la IA en la educación superior para fomentar una educación inclusiva, innovadora y de calidad (UNESCO, 2021).

A pesar del crecimiento acelerado de estudios sobre inteligencia artificial en educación, la mayoría de las investigaciones se han centrado en percepciones generales, experiencias cualitativas o actitudes hacia tecnologías de IAG en un sentido amplio. Son escasos los instrumentos psicométricamente validados que permitan medir de manera específica la aceptación y uso de la IAG en docentes, particularmente en el contexto de la educación superior. Es por ello que el objetivo de esta investigación es: adaptar y validar un instrumento confiable y válido que permita evaluar la aceptación y el uso de la IAG en docentes, con base en el TAM.

METODOLOGÍA

La presente investigación tiene un enfoque cuantitativo, dado que se fundamenta en la recolección y análisis de datos numéricos con el propósito de examinar relaciones entre variables mediante procedimientos estadísticos (Hernández et al., 2014).

En cuanto al diseño metodológico, se trata de un estudio no experimental y de carácter instrumental, ya que no se manipularon deliberadamente las variables independientes; en su lugar, los fenómenos se observaron tal como ocurren en su contexto natural, sin intervención del investigador (Hernández et al., 2014). Conforme a Montero y León (2002) y Ato et al. (2013), los estudios instrumentales se orientan al análisis, desarrollo, adaptación o validación de instrumentos destinados a la medición de variables específicas.

El proceso de adaptación y validación se llevó a cabo en cinco etapas:

1. Revisión de la literatura.
2. Adaptación del instrumento.
3. Evaluación por panel de expertos.
4. Prueba piloto.
5. Pruebas estadísticas de validación para evaluar las propiedades psicométricas del instrumento, incluyendo la validez factorial y la confiabilidad interna. Esto incluyó un análisis factorial exploratorio (AFE) y un análisis factorial confirmatorio (AFC), así como la evaluación de índices de ajuste y cargas factoriales.

Revisión de la literatura

Se realizó una búsqueda exhaustiva de investigaciones previas relacionadas con el modelo de aceptación de tecnología (TAM) y su aplicación en diversos contextos, especialmente en el ámbito educativo y con tecnologías emergentes como la IAG. Para el desarrollo del instrumento, se revisaron estudios que han adaptado el TAM para evaluar la aceptación de tecnologías emergentes por parte de docentes y estudiantes, con el fin de identificar ítems pertinentes y representativos de los constructos clave: Utilidad Percibida, Facilidad de Uso Percibida, Actitud hacia el Uso e Intención de Uso.

Siguiendo esta lógica, se realizó una revisión comparativa de las versiones adaptadas del TAM reportadas en la literatura reciente. Esta revisión permitió identificar patrones comunes en la redacción de los ítems, así como ajustes conceptuales necesarios para incorporar la tecnología objeto de este estudio: la IAG. Además, se priorizó el uso de un lenguaje claro, adecuado al contexto educativo y comprensible para docentes de diferentes disciplinas, tal como recomiendan Hernández et al. (2014), en el diseño de instrumentos de medición en ciencias sociales. La búsqueda se realizó en bases de datos académicas como Scopus, Web of Science y Google Scholar.

Adaptación del instrumento

Con base en la literatura revisada, se seleccionaron y reformularon ítems para garantizar su pertinencia en el contexto de este estudio. En primera instancia, se elaboró una versión preliminar compuesta por 20 ítems distribuidos en los cuatro factores del modelo original. El cuestionario se estructuró bajo una escala tipo Likert de cinco puntos, donde 1 = totalmente en desacuerdo y 5 = totalmente de acuerdo.

Evaluación por panel de expertos

El panel de expertos estuvo conformado por tres docentes con experiencia en investigación educativa y uso de tecnologías digitales en educación superior. A partir de sus observaciones se realizaron ajustes para mejorar la calidad del instrumento. Enseguida, como parte del proceso de validación del instrumento, se llevó a cabo una validación de contenido donde los docentes evaluaron los ítems con base en los criterios de suficiencia, relevancia, claridad y coherencia, utilizando la matriz de valoración desarrollada por Escobar-Pérez y Cuervo-Martínez (2008).

Cada ítem fue calificado en una escala de 1 a 4. Los resultados de esta revisión indicaron que la mayoría de los ítems fueron valorados con niveles altos de congruencia, lo que respalda la adecuación conceptual del instrumento para el contexto de estudio. Las observaciones emitidas por los jueces fueron consideradas para realizar ajustes que fortalecieran la precisión semántica y la coherencia interna de los ítems. Este proceso permitió fortalecer la validez de contenido del instrumento antes de su aplicación piloto. Como resultado se realizó el cuestionario que se nombró Escala de Aceptación y Uso de la Inteligencia Artificial Generativa (EAU-IAG) que se muestra en la tabla 1.

Tabla 1.

Escala de Aceptación y Uso de la Inteligencia Artificial Generativa (EAU-IAG)

# Ítem	Dimensión	Descripción
Item1	Utilidad Percibida (UP)	Las herramientas de inteligencia artificial generativa me ayudan a generar ideas nuevas y útiles para mi investigación o trabajo académico
Item2	Utilidad Percibida (UP)	Considero que el uso de herramientas de inteligencia artificial generativa mejora mi productividad en tareas relacionadas con la educación superior
Item3	Utilidad Percibida (UP)	Pienso que las herramientas de inteligencia artificial generativa facilitan la búsqueda y recopilación de información relevante para mis proyectos

Aceptación de la inteligencia artificial generativa en docentes: adaptación y validación de un instrumento basado en el TAM.

Item4	Utilidad Percibida (UP)	El uso de herramientas de inteligencia artificial generativa me permite explorar conceptos y temas de manera más profunda y completa
Item5	Utilidad Percibida (UP)	Las herramientas de inteligencia artificial generativa mejoran mi capacidad para comprender y abordar problemas complejos en mi área de especialización
Item6	Facilidad de Uso Percibida (FUP)	Considero que es fácil aprender a utilizar herramientas de inteligencia artificial generativa
Item7	Facilidad de Uso Percibida (FUP)	La interfaz de las herramientas de inteligencia artificial generativa me resulta intuitiva y fácil de navegar.
Item8	Facilidad de Uso Percibida (FUP)	No tengo dificultades para formular preguntas o solicitar información a través de herramientas de inteligencia artificial generativa
Item9	Facilidad de Uso Percibida (FUP)	En general, creo que utilizar herramientas de inteligencia artificial generativa requiere poco esfuerzo de aprendizaje
Item10	Facilidad de Uso Percibida (FUP)	Las herramientas de inteligencia artificial generativa responden con rapidez a mis consultas y solicitudes
Item11	Actitud Hacia el Uso (AU)	Me siento entusiasta con la idea de utilizar herramientas de inteligencia artificial generativa en mis actividades académicas o de investigación
Item12	Actitud Hacia el Uso (AU)	Considero que las herramientas de inteligencia artificial generativa son valiosas para mejorar mi desempeño en la educación superior
Item13	Actitud Hacia el Uso (AU)	Confío en la capacidad de las herramientas de inteligencia artificial generativa para proporcionar respuestas precisas y útiles.
Item14	Actitud Hacia el Uso (AU)	Considero que utilizar herramientas de inteligencia artificial generativa enriquece mi experiencia de aprendizaje o investigación
Item15	Actitud Hacia el Uso (AU)	Me siento cómodo/a y seguro/a al interactuar con herramientas de inteligencia artificial generativa
Item16	Intención de Uso (IU)	Planeo utilizar herramientas de inteligencia artificial generativa con frecuencia en el futuro para mis proyectos académicos o de investigación
Item17	Intención de Uso (IU)	Me imagino utilizando herramientas de inteligencia artificial generativa regularmente como parte de mi rutina de trabajo en la educación superior
Item18	Intención de Uso (IU)	Estoy motivado/a para explorar todas las capacidades y funciones de las herramientas de inteligencia artificial generativa en mis actividades diarias
Item19	Intención de Uso (IU)	Creo que las herramientas de inteligencia artificial generativa serán indispensables en mi trabajo académico o profesional
Item20	Intención de Uso (IU)	Recomendaría el uso de herramientas de inteligencia artificial generativa a mis colegas y compañeros de trabajo

Fuente: Elaboración propia a partir del modelo TAM

Prueba piloto

Se aplicó el cuestionario a un grupo de 100 docentes. El tamaño muestral ($n = 100$) se considera adecuado para estudios instrumentales y análisis factorial, ya que cumple con el criterio mínimo recomendado de 5 participantes por ítem (Hair et al., 2019), considerando que el instrumento está compuesto por 20 reactivos. Para llevar a cabo la prueba piloto, se utilizó formularios de Google y su distribución se realizó por medio del correo institucional. El muestreo fue no probabilístico por conveniencia, dado que la participación dependió de la disponibilidad y disposición de los docentes.

Tras la recolección de los datos, la información fue exportada al software estadístico SPSS, donde se configuraron las variables y los tipos de datos correspondientes. En el proceso de

carga y análisis de la prueba piloto se obtuvieron 100 casos válidos, sin que se excluyera ninguno. El análisis descriptivo de la prueba piloto reveló que el 57% de los participantes fueron hombres ($n = 57$) y el 43% mujeres ($n = 43$). La edad de los participantes osciló entre los 32 y los 79 años, con una media de 52 años y una desviación estándar de 11.

RESULTADOS

Con el propósito de identificar la estructura subyacente de los datos y verificar la agrupación empírica de los ítems en sus respectivos factores se realizó el Análisis Factorial Exploratorio (AFE). Esta técnica estadística permite explorar la dimensionalidad del instrumento y evaluar la coherencia interna de los constructos teóricos propuestos (Hair et al., 2019). El AFE se realizó con el método de extracción de componentes principales y rotación Varimax con la prueba de Kaiser-Meyer-Olkin (KMO) y la prueba de esfericidad de Bartlett.

El índice KMO obtenido fue de .751, valor que se considera admisible y dentro del rango aceptable para la aplicación del análisis factorial (Kaiser, 1974). Este valor indica que la muestra es adecuada para aplicar análisis factorial, ya que existe una correlación suficiente entre los ítems del instrumento. La prueba de esfericidad de Bartlett resultó significativa ($\chi^2(190) = 907.149, p < .001$).

Esta significancia estadística confirma la existencia de correlaciones significativas entre los ítems, lo que justifica la pertinencia del AFE para explorar la estructura del constructo (Kaiser, 1974). En la tabla 2, se observa los resultados del análisis de la idoneidad de los datos para aplicar técnicas factoriales.

Tabla 2.

Medidas de adecuación para el análisis factorial

Prueba	Valor
KMO	.751
χ^2 de Bartlett	907.149
gl	190
Sig.	.000

Fuente: Elaboración propia con resultados de SPSS

La Tabla 3, muestra la varianza total explicada por cada factor antes de la extracción y después de la rotación. El análisis reveló que los cuatro primeros factores presentaron autovalores iniciales superiores a 1.0, criterio comúnmente utilizado para determinar el número de factores significativos a retener (Kaiser, 1960). Estos cuatro factores explicaron el 63.96% de la varianza total de los datos. Este porcentaje sugiere que el modelo de cuatro factores captura una proporción sustancial de la variabilidad en las respuestas de los docentes, indicando una buena representación de la estructura subyacente del constructo de aceptación de la IAG.

Tabla 3.

Varianza total explicada por los componentes


Componente	Autovalor	% de Varianza	% Acumulado
1	3.762	17.41%	17.41%
2	3.571	15.93%	33.34%
3	2.841	15.52%	48.85%
4	2.617	15.11%	63.96%

Fuente: Elaboración propia con resultados de SPSS

La distribución de la varianza explicada por cada componente fue la siguiente: el primer componente explicó el 17.41% de la varianza, el segundo el 15.93%, el tercero el 15.52% y el cuarto el 15.11%. Este nivel de varianza explicada es consistente con los estándares aceptados en investigación en Ciencias Sociales (Hair et al., 2019). La Figura 1, muestra un diagrama de sedimentación de los componentes y la carga de sus autovalores. Los primeros componentes tienen autovalores altos, lo que explican una gran parte de la varianza total.

Figura 1.

Gráfico de sedimentación



Fuente: Elaboración propia con resultados de SPSS

En el gráfico, se observa una pendiente pronunciada en los primeros componentes, seguida de una curva que se aplana a partir del componente 5. Este patrón indica que los primeros factores explican una proporción significativa de la varianza total del instrumento, mientras que los factores posteriores aportan una menor cantidad de información. El punto de inflexión o "codo" del gráfico, que representa el cambio en la pendiente, sugiere el número óptimo de factores a retener.

De acuerdo con el criterio sugerido de Cattell (1966), se recomienda conservar los factores anteriores al punto donde la curva se estabiliza, ya que estos representan estructuras latentes significativas. En este caso, el gráfico sugiere la retención de cuatro factores. Esta evidencia gráfica respalda la validez estructural del instrumento.

Para facilitar la interpretación de los factores extraídos, se aplicó una rotación ortogonal Varimax, la cual es ampliamente utilizada en análisis factorial exploratorio. Esta técnica busca maximizar la varianza de las cargas al cuadrado dentro de cada factor, lo que permite que cada ítem se asocie fuertemente con un solo factor y débilmente con los demás. De acuerdo con Tabachnick y Fidell (2019), la rotación Varimax contribuye a obtener una estructura factorial más clara y simple, lo que mejora la comprensión y la validez interpretativa del modelo.

La matriz de componentes rotados (tabla 4) mostró una estructura clara de cuatro factores, consistente con las dimensiones teóricas del Modelo de Aceptación de Tecnología (TAM). Todos los ítems presentaron cargas factoriales elevadas y superiores al umbral mínimo recomendado, sin evidencias de cargas cruzadas significativas. Se consideraron cargas factoriales de 0.40 o superiores como significativas para la interpretación de los factores (Hair et al., 2019).

Tabla 4.

Matriz de componentes rotados

Ítem	Componente			
	AU (1)	IU (2)	UP (3)	FUP (4)
Item13	.876			
Item15	.825			
Item14	.819			
Item12	.812			
Item11	.797			
Item18		.879		
Item16		.788		
Item17		.773		
Item19		.771		
Item20		.721		
Item5			.841	
Item4			.828	
Item2			.763	
Item1			.726	
Item3			.725	
Item9				.800
Item10				.776
Item6				.772
Item7				.759
Item8				.685

Método de extracción: análisis de componentes principales.

Método de rotación: Varimax con normalización Kaiser.

La rotación ha convergido en 5 iteraciones

Fuente: Elaboración propia con resultados de SPSS

Enseguida, la confiabilidad interna del instrumento fue evaluada mediante el coeficiente Alfa de Cronbach, ampliamente utilizado para evaluar la consistencia interna de los instrumentos (Oviedo y Campo-Arias, 2005). Los resultados mostraron valores adecuados: actitud hacia el uso ($\alpha = .886$), intención de uso ($\alpha = .850$), utilidad percibida ($\alpha = .835$) y facilidad de uso percibida ($\alpha = .820$). Estos valores indican que los ítems de cada dimensión están altamente correlacionados y son apropiados para medir constructos relacionados con la percepción y el uso de la IAG por parte de docentes de educación superior. Los valores se presentan en la tabla 5.

Tabla 5.

Tabla de confiabilidad

Dimensión TAM	Alfa de Cronbach	Interpretación
Utilidad Percibida (UP)	0.835	Muy buena
Facilidad de Uso Percibida (FUP)	0.820	Muy buena
Actitud hacia el uso (AU)	0.886	Muy buena
Intención de uso (IU)	0.850	Muy buena

Fuente: Elaboración propia con resultados de SPSS

El valor del coeficiente alfa de Cronbach total fue de 0.774, lo cual, si bien se encuentra ligeramente por debajo del umbral convencional de 0.80 para una alta consistencia interna, de acuerdo con los criterios propuestos por Hernández et al. (2014), este valor se considera aceptable, lo que indica que los ítems del cuestionario presentan una adecuada homogeneidad y miden de manera coherente el constructo de interés.

Tras la realización del AFE y con base en la estructura factorial identificada, se procedió a efectuar un Análisis Factorial Confirmatorio (AFC) utilizando la librería *semopy* con Python, como parte del proceso de validación del instrumento. Python se ha consolidado como una plataforma robusta, flexible y de código abierto en el ámbito académico y científico, como una alternativa poderosa frente a software tradicional como SPSS gracias a su amplio repertorio de librerías estadísticas (Rodríguez-Rivas y Rodríguez, 2022).

El AFC permitió evaluar empíricamente el ajuste del modelo teórico a los datos observados. Este análisis proporcionó evidencia de la validez estructural y permitió examinar la calidad del modelo de medición a través de índices de ajuste, cargas factoriales, errores estándar y significancia estadística (Brown, 2015; Kline, 2016).

Los resultados del AFC mostraron evidencias satisfactorias de validez factorial del modelo propuesto. En primer lugar, todas las cargas factoriales estandarizadas de los ítems sobre sus respectivos factores latentes fueron estadísticamente significativas ($p < .001$), con valores que oscilaron entre 0.59 y 0.87, cumpliendo con el umbral sugerido por Hair et al. (2019), quienes recomiendan valores superiores a 0.5 como aceptables y superiores a 0.7 como deseables para modelos confirmatorios.

Estos resultados evidencian que cada ítem contribuye de manera adecuada a la medición del constructo teórico al que pertenece. Los valores completos los observamos en la tabla 6.

Tabla 6.

Cargas factoriales estandarizadas

Ítem	Factor	λ
Item1	UP	0.63
Item2	UP	0.70
Item3	UP	0.64
Item4	UP	0.80
Item5	UP	0.80
Item6	FUP	0.70
Item7	FUP	0.70
Item8	FUP	0.59
Item9	FUP	0.76
Item10	FUP	0.71
Item11	AU	0.72
Item12	AU	0.77
Item13	AU	0.86
Item14	AU	0.80
Item15	AU	0.76
Item16	IU	0.73
Item17	IU	0.67
Item18	IU	0.87
Item19	IU	0.73
Item20	IU	0.66


Fuente: Elaboración propia con resultados de Python y *semopy*

El constructo Utilidad Percibida (UP) compuesta del ítem1 a ítem5, los resultados del AFC mostraron que todos los reactivos presentaron cargas factoriales elevadas, con valores que oscilan entre 0.63 y 0.80, lo que indica una fuerte relación entre los ítems. Además, todos los coeficientes fueron estadísticamente significativos ($p < 0.001$).

El modelo fue representado gráficamente a través de un diagrama de rutas, lo cual facilita la visualización de la estructura del instrumento de medición. En este diagrama, los factores latentes se representan mediante óvalos y los ítems observados como rectángulos. La figura 2, muestra el diagrama de rutas correspondiente al factor UP, donde se visualizan las cargas factoriales y los valores p asociados a cada reactivo.

Figura 2.

Diagrama de rutas UP

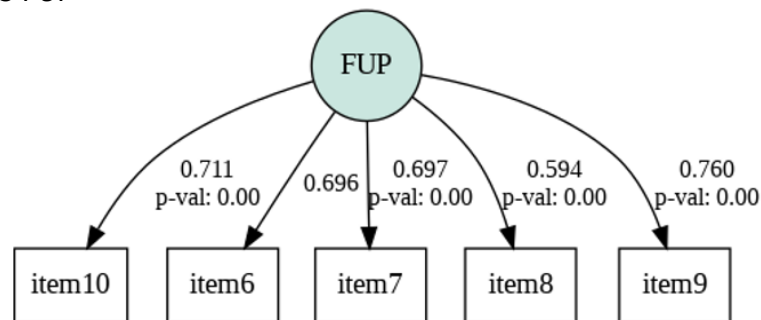


Fuente: Elaboración propia con resultados de Python y semopy

La Facilidad de Uso Percibida (FUP) fue evaluada mediante los ítems (item6 a item10). Los resultados del AFC indicaron que todos los ítems presentaron cargas factoriales adecuadas, con valores que van desde 0.59 hasta 0.76. Estos resultados reflejan una relación sólida entre los ítems y el constructo FUP, aunque con una ligera menor intensidad en comparación con los demás factores del modelo. Todos los coeficientes fueron estadísticamente significativos ($p < 0.001$), lo que respalda la validez de los ítems como indicadores del factor. En la figura 3, se presenta el diagrama de rutas.

Figura 3.

Diagrama de rutas FUP




Fuente: Elaboración propia con resultados de Python y semopy

En cuanto al constructo Actitud hacia el Uso (AU) fue medido mediante los reactivos item11 a item15. Los resultados del AFC revelaron que todos presentaron cargas factoriales altas, con valores que oscilan entre 0.72 y 0.86, lo que indica una fuerte asociación entre los ítems y el factor AU. Todos los coeficientes fueron estadísticamente significativos ($p < 0.001$), lo que respalda la validez como indicadores confiables. En la figura 4, podemos ver el diagrama de rutas donde se visualizan las cargas factoriales y los valores p asociados a cada reactivo.

Figura 4.

Diagrama de rutas AU




Fuente: Elaboración propia con resultados de Python y semopy

De manera similar, el constructo de Intención de Uso (IU) fue evaluado con los reactivos item16 a item20. Los resultados del análisis factorial confirmatorio mostraron que todos los ítems presentaron cargas factoriales altas, con valores que van desde 0.66 hasta 0.87, lo que indica una fuerte relación entre los ítems y el constructo IU. De la misma forma, todos los coeficientes fueron estadísticamente significativos ($p < 0.001$), lo que respalda la validez de estos ítems como indicadores del factor. En la figura 5, se presenta el diagrama de rutas correspondiente al factor IU, donde se visualizan las cargas factoriales y los valores p asociados a cada ítem.

Figura 5.

Diagrama de rutas IU



Fuente: Elaboración propia con resultados de Python y semopy

Por otra parte, los índices globales de ajuste indican un buen ajuste del modelo. El índice CFI (0.969) y el TLI (0.964) se encuentran por encima del valor recomendado de 0.95, mientras que el RMSEA fue de 0.039, por debajo del umbral de 0.06, lo que sugiere un error de aproximación bajo (Hu y Bentler, 1999). De igual forma, el valor p asociado a chi-cuadrado ($\chi^2 = 188.67$, $p = 0.091$) no fue significativo. Aunque los índices GFI y AGFI presentan valores moderados, se priorizaron índices incrementales y de error de aproximación (CFI, TLI y RMSEA), conforme a las recomendaciones actuales en modelos de ecuaciones estructurales (Hu y Bentler, 1999; Kline, 2016). Los índices de ajuste se presentan en la Tabla 7.

Tabla 7.

Índices globales de ajuste del modelo

Índice	Valor	Criterio recomendado	Interpretación
χ^2 (p -valor)	188.67 ($p = .091$)	$p > .05$	No significativo
GFI	0.810	> 0.90	Aceptable
AGFI	0.780	> 0.90	Aceptable
CFI	0.969	> 0.95	Excelente ajuste
TLI	0.964	> 0.95	Excelente ajuste
RMSEA	0.039	< 0.06	Muy buen ajuste
AIC	88.23	--	Comparativo, menor es mejor

Fuente: Elaboración propia con resultados de Python y semopy

La evidencia obtenida permite afirmar que el modelo de medición propuesto, modificado a partir del TAM, mostró adecuada validez factorial confirmatoria con excelentes índices de ajuste, cargas factoriales sólidas y una organización interna coherente. Estos resultados respaldan el uso del instrumento como una herramienta válida para evaluar la percepción y el uso de la IAG por parte de docentes de educación superior.

De manera general, los resultados del AFE, AFC y los coeficientes Alfa de Cronbach obtenidos para cada dimensión, permiten concluir que el instrumento es válido y confiable para medir la percepción y el uso de la IAG. Dicha evidencia empírica es fundamental para estudios posteriores que busquen comprender los determinantes del uso educativo de tecnologías emergentes en la enseñanza superior (OECD, 2021).

CONCLUSIONES

El objetivo de esta investigación fue diseñar y validar un instrumento que permitiera evaluar la aceptación y el uso de IAG en docentes de educación superior, con base en el TAM. A partir de los análisis realizados, se puede afirmar que dicho objetivo fue alcanzado, dando como resultado la Escala de Aceptación y Uso de la Inteligencia Artificial Generativa (EAU-IAG), la cual presenta propiedades psicométricas adecuadas para su aplicación en contextos educativos.

La evidencia obtenida mediante el Análisis Factorial Exploratorio permitió identificar una estructura de cuatro factores coherente con el modelo teórico del TAM, explicando una proporción sustancial de la varianza total. Posteriormente, el Análisis Factorial Confirmatorio corroboró la validez factorial del modelo propuesto, mostrando cargas factoriales estandarizadas adecuadas y estadísticamente significativas, así como índices globales de ajuste que indican un muy buen ajuste del modelo a los datos. De igual forma, los coeficientes de confiabilidad evidenciaron una alta consistencia interna tanto por dimensión como a nivel global.

En cuanto a las limitaciones del estudio, es importante señalar que la muestra estuvo conformada por docentes de una sola institución de educación superior y fue seleccionada mediante un muestreo no probabilístico por conveniencia, lo que puede limitar la generalización de los resultados. Asimismo, para la recolección de datos se realizó a través de correo electrónico, lo cual podría introducir un sesgo de cobertura, particularmente aquellos con menor familiaridad tecnológica podrían no estar representados en la muestra, lo que podría afectar la generalización de los resultados.

A pesar de estas limitaciones, el instrumento desarrollado constituye un aporte relevante para la investigación educativa, al proporcionar una herramienta válida y confiable para evaluar la aceptación de la inteligencia artificial generativa en docentes. La EAU-IAG puede emplearse

en estudios diagnósticos, evaluaciones institucionales y futuras investigaciones orientadas a analizar los factores que influyen en la adopción de tecnologías emergentes, así como para apoyar el diseño de estrategias de formación docente y políticas de integración responsable de la inteligencia artificial en la educación superior.

LIMITACIONES Y ESTUDIOS FUTUROS

El presente estudio presenta algunas limitaciones. En primer lugar, la muestra estuvo conformada por docentes de educación superior pertenecientes a una institución, lo que podría limitar la generalización de los resultados a otros niveles educativos o contextos. Asimismo, los datos se obtuvieron mediante autoinforme, por lo que reflejan percepciones de los participantes sobre la aceptación y uso de la inteligencia artificial generativa, y no necesariamente su uso real en la práctica docente.

En futuras investigaciones se sugiere aplicar la escala en muestras más amplias y diversas, incluyendo docentes de distintos niveles educativos y contextos institucionales, con el fin de analizar la estabilidad del modelo factorial y fortalecer la validez externa del instrumento.

Asimismo, se sugiere que futuras investigaciones apliquen el instrumento incorporando variables adicionales que permitan identificar las herramientas de IAG que utilizan los docentes y los propósitos específicos de su uso en la práctica educativa, tales como la generación de materiales didácticos, apoyo en la planificación de clases, elaboración de evaluaciones o asistencia en procesos de investigación académica. Esto permitiría comprender con mayor detalle los patrones de uso y las aplicaciones concretas de estas tecnologías en el ámbito educativo.

RECONOCIMIENTO

Los autores agradecen la colaboración brindada por los estudiantes participantes en el estudio y el apoyo de la institución.

ROL DE LOS AUTORES

José Gabriel Rodríguez-Rivas: Conceptualización, Investigación, Validación, Análisis formal, Visualización, Curación de datos

Fernando Ayala Partida: Metodología, Redacción, Edición, Supervisión

Luis Campa Galindo: Metodología, Redacción, Revisión, Validación

CONFLICTO DE INTERÉS

Los autores declaran que no existe conflicto de interés en relación con la investigación, autoría y/o publicación del presente artículo.

REFERENCIAS

- Alier, M., García Peñalvo, F. J., and D. Camba, J. (2024). Generative Artificial Intelligence in Education: From Deceptive to Disruptive. *International Journal of Interactive Multimedia and Artificial Intelligence*, 8(5), 5–14. <https://doi.org/10.9781/ijimai.2024.02.011>
- Al-Rahmi, W. M., Yahaya, N., Aldraiweesh, A. A., Alturki, U., Alamri, M. M., Saud, M. S. B., ... & Alhamed, O. A. (2019). Big data adoption and knowledge management sharing: An empirical investigation on their adoption and sustainability as a purpose of education. *IEEE Access*, 7, 47245–47258. <https://doi.org/10.1109/ACCESS.2019.2906668>

- Ato, M., López, J. J., & Benavente, A. (2013). Un sistema de clasificación de los diseños de investigación en psicología. *Anales de Psicología*, 29(3). <https://doi.org/10.6018/analesps.29.3.178511>
- Brown, T. A. (2015). *Confirmatory Factor Analysis for Applied Research* (2nd ed.). The Guilford Press.
- Cattell, R. B. (1966). The Scree Test For The Number Of Factors. *Multivariate Behavioral Research*, 1(2), 245–276. https://doi.org/10.1207/s15327906mbr0102_10
- 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>
- Davis, F. D., & Granić, A. (2024). *The Technology Acceptance Model: 30 Years of TAM*. Springer. <https://link.springer.com/book/10.1007/978-3-030-45274-2>
- Escobar-Pérez, J., & Cuervo-Martínez, Á. (2008). Validez de contenido y juicio de expertos: Una aproximación a su utilización. *Avances en Medición*, 6(1), 27-36.
- Evayani, E., Indriani, M., Chan, S., Syam, F. (2024). Technology Acceptance Model in the SMEs and Moving Forward: A Systematic Literature Review from 1986 to 2021. In: Alareeni, B., Hamdan, A. (Eds.), *Technology and Business Model Innovation: Challenges and Opportunities*. (pp. 265–273). Springer. https://doi.org/10.1007/978-3-031-55911-2_25
- Gallent-Torres, C., Zapata-González, A., & Ortego-Hernando, J. L. (2023). El impacto de la inteligencia artificial generativa en educación superior: una mirada desde la ética y la integridad académica. *Revista Electrónica de Investigación y Evaluación Educativa*, 29(2), 1-21. <https://doi.org/10.30827/relieve.v29i2.29134>
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate data analysis* (8th ed.). Cengage Learning.
- Hernández, R., Fernández, C., & Baptista, P. (2014). *Metodología de la investigación* (6.ª ed.). McGraw-Hill.
- Hu, L. T., & Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural Equation Modeling: A Multidisciplinary Journal*, 6(1), 1–55. <https://doi.org/10.1080/10705519909540118>
- Kaiser, H. F. (1960). The application of electronic computers to factor analysis. *Educational and Psychological Measurement*, 20(1), 141–151. <https://doi.org/10.1177/001316446002000116>
- Kaiser, H. F. (1974). An index of factorial simplicity. *Psychometrika*, 39(1), 31–36. <https://doi.org/10.1007/BF02291575>
- Kalota, F. (2024). A Primer on Generative Artificial Intelligence. *Education Sciences*, 14(2), 172. <https://doi.org/10.3390/educsci14020172>
- King, W. R., & He, J. (2006). A meta-analysis of the technology acceptance model. *Information & Management*, 43(6), 740–755. <https://doi.org/10.1016/j.im.2006.05.003>
- Kline, R. B. (2016). *Principles and Practice of Structural Equation Modeling* (4th ed.). The Guilford Press.
- Montero, I., & León, O. G. (2002). Clasificación y descripción de las metodologías de investigación en psicología. *Revista Internacional de Psicología Clínica y de La Salud*, 2(3), 503-508. <https://www.redalyc.org/articulo.oa?id=33720308>
- Na, S., Heo, S., Han, S., Shin, Y., & Roh, Y. (2022). Acceptance Model of Artificial Intelligence (AI)-Based Technologies in Construction Firms: Applying the Technology Acceptance

- Model (TAM) in Combination with the Technology–Organisation–Environment (TOE) Framework. *Buildings*, 12(2). <https://doi.org/10.3390/buildings12020090>
- Organización para la Cooperación y el Desarrollo Económico [OECD]. (2021). *AI and the Future of Skills, Volume 1: Capabilities and Assessments, Educational Research and Innovation*, OECD Publishing. <https://doi.org/10.1787/5ee71f34-en>
- Oviedo, H. C., & Campo-Arias, A. (2005). Aproximación al uso del coeficiente alfa de Cronbach. *Revista colombiana de psiquiatría*, 34(4), 572-580.
- Pizarro, G. R., Rodríguez-Rivas, J. G., Dominguez, F. A. S & Rivera, S. E. (2025). Calidad de Información de Respuestas de las Herramientas de Inteligencia Artificial Generativa Tipo Texto. *Estudios y Perspectivas Revista Científica y Académica*, 5(3), 4226-4252.
- Prasetyo, Y. T., Ong, A. K. S., Concepcion, G. K. F., Navata, F. M. B., Robles, R. A. V., Tomagos, I. J. T., Young, M. N., Diaz, J. F. T., Nadlifatin, R., & Redi, A. A. N. P. (2021). Determining factors affecting acceptance of e-learning platforms during the covid-19 pandemic: Integrating extended technology acceptance model and delone & mclean is success model. *Sustainability*, 13(15). <https://doi.org/10.3390/su13158365>
- Rodríguez-Rivas, J. G., & Rodríguez, C. S. (2022). Uso de Python para el análisis de datos aplicado en la investigación. *Investigación y Ciencia Aplicada a La Ingeniería*, 5(34), 33-40. <https://ojsincaing.com.mx/index.php/ediciones/article/view/188>
- Santiago-Trujillo, Y. D., & Garvich-Ormeño, R. M. (2024). Competencias Digitales e Integración de las TIC en el Proceso de Enseñanza-Aprendizaje. *Revista Docentes 2.0*. https://ve.scielo.org/scielo.php?script=sci_arttext&pid=S2665-02662024000100050
- Shin, J., Park, Y., & Lee, D. (2018). Who will be smart home users? An analysis of adoption and diffusion of smart homes. *Technological Forecasting and Social Change*, 134, 246–253. <https://doi.org/10.1016/j.techfore.2018.06.029>
- Tabachnick, B. G., & Fidell, L. S. (2019). *Using multivariate statistics* (7th ed.). Pearson.
- 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>
- Timotheou, S., Miliou, O., Dimitriadis, Y. (2023). Impacts of digital technologies on education and factors influencing schools' digital capacity and transformation: A literature review. *Educ Inf Technol* 28, 6695–6726. <https://doi.org/10.1007/s10639-022-11431-8>
- UNESCO. (2021). *Artificial Intelligence in Education: Challenges and Opportunities for Sustainable Development*. UNESCO Publishing. <https://unesdoc.unesco.org/ark:/48223/pf0000366994>
- Venkatesh, V., & Bala, H. (2008). Technology acceptance model 3 and a research agenda on interventions. *Decision Sciences*, 39(2), 273–315. <https://doi.org/10.1111/j.1540-5915.2008.00192.x>
- Venkatesh, V., & Davis, F. D. (2000). A theoretical extension of the Technology Acceptance Model: Four longitudinal field studies. *Management Science*, 46(2), 186–204. <https://doi.org/10.1287/mnsc.46.2.186.11926>
- Venkatesh, V., Morris, M. G., Davis, G. B., & 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>