

Ciencia Latina Revista Científica Multidisciplinar, Ciudad de México, México.
ISSN 2707-2207 / ISSN 2707-2215 (en línea), marzo-abril 2025,
Volumen 9, Número 2.

https://doi.org/10.37811/cl_rcm.v9i2

VALIDACIÓN DE UNA ESCALA SOBRE LA PERCEPCIÓN DE LA INTELIGENCIA ARTIFICIAL EN LA EDUCACIÓN SUPERIOR

**VALIDATION OF A SCALE ON THE PERCEPTION OF
ARTIFICIAL INTELLIGENCE IN HIGHER EDUCATION**

Carlos Arturo Torres-Gastelú
Universidad Veracruzana

Carlos Torres-Real
Universidad Veracruzana

DOI: https://doi.org/10.37811/cl_rcm.v9i2.17324

Validación de una escala sobre la percepción de la Inteligencia Artificial en la educación superior

Carlos Arturo Torres-Gastelú¹

torresgastelu@gmail.com

<https://orcid.org/0000-0003-2527-9602>

Universidad Veracruzana
Veracruz, México

Carlos Torres-Real

ctorresreal@hotmail.com

<https://orcid.org/0000-0003-3500-7803>

Universidad Veracruzana
Boca del Río, México

RESUMEN

La IA tiene el potencial para personalizar el aprendizaje, automatizar evaluaciones y proporcionar retroalimentación inmediata. El objetivo del artículo es describir el proceso de diseño y validación de la escala de percepción titulada PEIIA, creada para medir la percepción de la Inteligencia Artificial en la educación superior. La escala tipo Likert desarrollada contiene nueve dimensiones: efectividad de uso de la IA, mejoras de aprendizaje, dependencia cognitiva y tecnológica, facilidad de uso, apoyo hacia el aprendizaje, reacciones emocionales hacia la IA, precisión de la IA, aversión hacia el uso de la IA y percepción docente. Se aplicó a 1010 estudiantes inscritos en una universidad pública mexicana (58.9% de mujeres y 41.1% de hombres). Se realizó un análisis factorial exploratorio (AFE) y análisis factorial confirmatorio (AFC) para determinar su validez, que derivó en la eliminación de ítems con baja o nula correlación. Como parte de los resultados, se obtuvo un alfa de Cronbach de 0.945 y un índice Kaiser-Meyer-Olkin (KMO) de 0.960 global para las siete subescalas. La versión final contiene 35 ítems agrupados en siete factores. La escala PEIIA cuenta con un nivel aceptable de confiabilidad y validez para medir la percepción de la Inteligencia Artificial en la educación superior.

Palabras clave: aprendizaje, enseñanza, estudiante universitario, inteligencia artificial, medición

¹ Autor principal.

Correspondencia: torresgastelu@gmail.com

Validation of a scale on the perception of Artificial Intelligence in higher education

ABSTRACT

AI has the potential to personalize learning, automate assessments, and provide immediate feedback. The objective of this article is to describe the design and validation process of the perception scale titled PEIIA, created to measure the perception of Artificial Intelligence in higher education. The Likert-type scale developed contains nine dimensions: effectiveness of AI use, learning improvements, cognitive and technological dependence, ease of use, learning support, emotional reactions to AI, AI accuracy, aversion to AI use, and teacher perception. It was applied to 1,010 students enrolled in a Mexican public university (58.9% women and 41.1% men). An exploratory factor analysis (EFA) and confirmatory factor analysis (CFA) were performed to determine its validity, which led to the elimination of items with low or no correlation. The results showed a Cronbach's alpha of 0.945 and a Kaiser-Meyer-Olkin (KMO) index of 0.960 overall for the seven subscales. The final version contains 35 items grouped into seven factors. The PEIIA scale has an acceptable level of reliability and validity for measuring perceptions of Artificial Intelligence in higher education.

Keywords: learning, teaching, college student, artificial intelligence, measurement

Artículo recibido 08 marzo 2025

Aceptado para publicación: 15 abril 2025



INTRODUCCIÓN

La inteligencia artificial (IA) se ha consolidado como un campo de investigación y aplicación de vanguardia, transformando numerosos sectores de la sociedad, incluida la educación superior (Vera et al., 2023). Su integración, especialmente a través de herramientas de IA generativa como ChatGPT, ha despertado un interés creciente en la comunidad académica, modificando las dinámicas de enseñanza y aprendizaje (Larico, 2024). La IA, definida como la disciplina científica que desarrolla programas informáticos o máquinas capaces de simular tareas cognitivas humanas, como aprender, razonar y tomar decisiones autónomas (Vera et al., 2023), está revolucionando el panorama educativo (Cruz et al., 2024). Su potencial para personalizar el aprendizaje, automatizar evaluaciones, proporcionar retroalimentación inmediata y reducir brechas de habilidades es considerable.

Sin embargo, la rápida adopción de la IA en las universidades no está exenta de desafíos significativos. Preocupaciones sobre la integridad académica, el plagio, la ética en el uso de datos estudiantiles, los sesgos algorítmicos, la privacidad y la posible disminución del pensamiento crítico son temas recurrentes en la literatura (Vera et al., 2023). Existe un debate sobre si la IA reemplazará ciertas funciones docentes o si actuará principalmente como una herramienta para aumentar las capacidades humanas (Negrete y Mosquera, 2025). Esta dualidad –el inmenso potencial junto a los riesgos inherentes– subraya la urgencia de comprender cómo los estudiantes universitarios interactúan realmente con estas tecnologías.

Ante este escenario, la medición rigurosa del uso de la IA por parte de los estudiantes se convierte en un imperativo. Ir más allá de las anécdotas y obtener datos sistemáticos es crucial para varios propósitos: informar el diseño de estrategias pedagógicas efectivas que integren la IA de manera significativa; desarrollar políticas institucionales claras y fundamentadas que guíen el uso ético y responsable; abordar proactivamente las preocupaciones éticas sobre equidad, sesgo y privacidad (Gallent et al., 2023); asegurar un acceso equitativo a las herramientas y al apoyo necesario (Vera et al., 2023); y, fundamentalmente, preparar a los estudiantes con las competencias necesarias para desenvolverse en un futuro laboral y social cada vez más mediado por la IA (Slimi, 2023). La creación y validación de instrumentos psicométricos robustos es esencial para lograr esta comprensión profunda (Narváez y Medina, 2024).



Es crucial reconocer que el propósito declarado del uso de la IA está directamente relacionado con las consideraciones éticas y la integridad académica. Utilizar la IA para generar ideas se percibe de manera muy diferente a emplearla para redactar trabajos completos y presentarlos como propios (Vera et al., 2023). Las políticas institucionales a menudo distinguen entre usos permitidos (por ejemplo, con reconocimiento explícito) y usos prohibidos, y las directrices éticas enfatizan la transparencia y la distinción entre la contribución humana y la generada por IA.

Además, los propósitos por los cuales los estudiantes utilizan la IA reflejan su comprensión (o falta de ella) de las capacidades y limitaciones de estas herramientas, así como sus estrategias de aprendizaje y motivaciones subyacentes (Yurt y Kasarci, 2024). Un estudiante que usa la IA principalmente para tareas básicas como la corrección gramatical (Swidan et al., 2025) probablemente tenga motivaciones y percepciones diferentes a uno que la emplea para análisis de investigación complejos. El uso de la IA para tutoría personalizada (Larico, 2024) puede indicar una orientación hacia el aprendizaje autodirigido, posiblemente vinculada a una alta motivación intrínseca o de utilidad (Yurt y Kasarci, 2024). Por el contrario, una dependencia excesiva de la IA para completar tareas podría señalar una baja autoeficacia, alta ansiedad o una fuerte presión por obtener resultados externos. Así, el patrón de propósitos reportados por un estudiante puede ayudar a perfilar su enfoque general hacia el aprendizaje y la integración tecnológica (Vera et al., 2023).

Partiendo de lo anterior, la percepción de la Inteligencia Artificial en la educación superior que se propone en el presente artículo queda conformada por nueve dimensiones: efectividad de uso de la IA, mejoras de aprendizaje, dependencia cognitiva y tecnológica, facilidad de uso, apoyo hacia el aprendizaje, reacciones emocionales hacia la IA, precisión de la IA, aversión hacia el uso de la IA y percepción docente.

Se partió de la pregunta de investigación: ¿Qué nivel de confiabilidad y validez posee la escala PEIIA para medir las percepciones de los estudiantes a nivel universitario hacia la incorporación de Inteligencia Artificial en el ámbito educativo? El objetivo de la investigación fue describir el proceso de confiabilidad y validez de la escala PEIIA. Se parte de la hipótesis de que dicho instrumento reúne los criterios de confiabilidad y validez necesarios para ser utilizada en estudiantes universitarios.



Estudios relacionados

Con respecto a la dimensión Efectividad de uso de la IA, de acuerdo con Osman (2025), la utilidad y la facilidad de uso influyen en la intención de uso *a través* de su impacto en la actitud general del estudiante hacia la tecnología. Un estudiante que percibe la IA como útil y fácil de usar desarrollará una actitud más positiva, lo que a su vez fortalecerá su intención de utilizarla.

Por otro lado, la autoeficacia en IA mide la confianza de los estudiantes en su habilidad para usar herramientas de IA de manera efectiva para lograr sus objetivos académicos (Yurt y Kasarci, 2024). La autoeficacia es un predictor bien establecido del uso de la tecnología y del rendimiento (García et al., 2022).

En relación con la dimensión Dependencia cognitiva y tecnológica, un tema recurrente en la investigación es la ambivalencia en las actitudes estudiantiles: reconocen los beneficios potenciales de la IA, pero al mismo tiempo albergan preocupaciones y ansiedades significativas (Katsantonis y Katsantonis, 2024). Los estudiantes pueden ver el potencial de la IA, pero tener reservas sobre su impacto laboral (Cao et al., 2023) o sobre la dependencia excesiva y los riesgos para la integridad (Alshamy et al., 2025).

Sobre la dimensión Facilidad de uso, investigaciones recientes establecen que los estudiantes que se sienten más competentes en el manejo de la IA tienden a confiar más en ella. Un estudio encontró que la AISE explicaba una parte significativa (32.9%) de la varianza en la Confianza en la IA (Aliño et al., 2024). Esto implica que las experiencias positivas y la percepción de competencia fomentan la confianza en los sistemas de IA.

La falta de confianza, alimentada por preocupaciones sobre la precisión, el sesgo y la privacidad (Khairuddin et al., 2024), actúa como una barrera significativa para la adopción de la IA. Para algunos estudiantes, estas preocupaciones pueden superar los beneficios percibidos. La desconfianza y el escepticismo se asocian a menudo con una falta de comprensión o experiencias negativas previas (Aliño et al., 2024).

Respecto a la dimensión Reacciones emocionales hacia la IA, los estudiantes sufren miedos y preocupaciones específicas, como el temor al reemplazo laboral futuro, la creencia de que la IA aumentará las desigualdades sociales, la preocupación por los peligros potenciales si no se regula



éticamente, o la percepción de consecuencias negativas en el aprendizaje (Vera et al., 2023). Un estudio encontró que la dimensión emocional de la actitud hacia la IA era la mejor valorada por los estudiantes (Katsantonis y Katsantonis, 2024).

Sobre la dimensión Precisión de la IA, la confianza en las capacidades y los resultados de la IA es otro factor psicológico determinante (Khairuddin et al., 2024). La confianza es crucial para el compromiso del usuario y la aceptación de las tecnologías de IA (Aliño et al., 2024). También son relevantes las preocupaciones sobre la fiabilidad y precisión de la IA, incluyendo el riesgo de sesgos incrustados en los algoritmos o la generación de información incorrecta o "alucinaciones" (Khairuddin et al., 2024).

En relación a la dimensión Aversión hacia el uso de la IA, un estudio encontró que el conocimiento sobre IA influía positivamente en la percepción de utilidad (Swidan et al., 2025). La desconfianza y el escepticismo a menudo se vinculan a la falta de comprensión, y existe una falta de conocimiento generalizada sobre la IA en la población (De Lara, 2022).

La teoría de la autoeficacia postula que la baja confianza lleva a evitar tareas desafiantes (Chávez et al., 2024). La ansiedad del usuario, influenciada por percepciones de baja facilidad de uso o baja autoeficacia, puede afectar negativamente la actitud y la adopción (Osman, 2025). La reducción de la ansiedad, por otro lado, puede mediar la relación entre la IA y la cognición creativa (Wang y Chuang, 2024).

METODOLOGÍA

Se trata de un tipo de estudio cuantitativo, no experimental y transversal que pretende identificar las percepciones de los estudiantes universitarios hacia el uso de la Inteligencia Artificial.

Participantes

El instrumento fue aplicado de manera presencial en una universidad pública mexicana alcanzando una muestra de 1010 estudiantes inscritos en el periodo agosto 2024-enero 2025 seleccionados de manera aleatoria a conveniencia del investigador. Se trata de una muestra no probabilística con la participación de siete licenciaturas. El instrumento se aplicó a la mayoría de los semestres excluyendo a los de nuevo ingreso. La composición de la muestra por sexo fue de 58.9% mujeres y 41.1% hombres. La distribución por edad, ordenada de menor a mayor, reveló que el 23.9% de los estudiantes tenían entre 18 y 19 años,



el 50.2% entre 20 y 21 años, el 19.8% entre 22 y 23 años, el 3.7% entre 24 y 25 años, y el 2.5% eran mayores de 26 años.

Instrumento

Se aplicó un instrumento conformado por 66 ítems valorado mediante una escala Likert de cinco opciones que van desde totalmente de acuerdo, de acuerdo, indiferente, en desacuerdo y totalmente en desacuerdo.

Procedimiento

La fiabilidad del instrumento se evaluó mediante el alfa de Cronbach, obteniendo un valor inicial de 0.949, lo que indica una alta consistencia interna. En tanto, la validez de contenido se hizo a través del juicio de expertos y la correspondiente revisión de la literatura. Al principio el instrumento estuvo conformado por nueve dimensiones, al término de la validación quedaron siete dimensiones con 35 ítems.

La recolección de datos cumplió con las normas éticas solicitando la autorización a las autoridades mediante la expedición de un oficio solicitando el apoyo para su aplicación. Los jefes de las diferentes licenciaturas proporcionaron un listado de horarios, días y maestros. También enviaron un correo a los maestros solicitando su apoyo. Antes de la aplicación, se les explicó el propósito del estudio y se les pidió que llenaran el consentimiento informado de los participantes, en el cual proporcionaron sus nombres y firmas. De la misma manera, se les indicó que se trataba de un estudio sin fines de lucro donde se respetaría la confidencialidad y el anonimato de sus respuestas.

Análisis de datos

Para la validación del instrumento se ejecutó el Análisis Factorial Exploratorio (AFE) mediante la identificación de los componentes principales y sus correspondientes pruebas de Alpha de Cronbach. En tanto, para el Análisis Factorial Confirmatorio (AFC) se emplearon índices de ajuste para evaluar el modelo teórico propuesto y su congruencia con los datos observados. Estas pruebas fueron realizadas con dos herramientas de Software: SPSS versión 25 y AMOS versión 23.



RESULTADOS Y DISCUSIÓN

Análisis descriptivos

Se realizaron análisis descriptivos como evidencia de la normalidad univariada en la distribución de los puntajes de los ítems. En la Tabla 1 se muestran los valores de medias (M), desviaciones estándar (DE), asimetría y curtosis de todos los ítems que componen el cuestionario PEIIA. Los valores de asimetría y curtosis sugieren la existencia de normalidad univariada en la distribución de los puntajes de los ítems, debido a que los valores de asimetría y curtosis se consideran aceptables, al encontrarse en los rangos de -3 a +3 y de -10 a +10, respectivamente (Griffin y Steinbrecher, 2013; Kline, 2016).

Tabla 1

Medias, desviaciones estándar, asimetría y curtosis de los 66 ítems iniciales de PEIIA

Ítems	M	DE	Asimetría	Curtosis	Ítems	M	DE	Asimetría	Curtosis
EIA1	3.86	0.980	-0.645	0.039	FDU34	4.06	0.949	-0.889	0.443
EIA2	3.46	1.084	-0.349	-0.383	FDU35	3.70	0.954	-0.335	-0.216
EIA3	3.64	1.066	-0.459	-0.372	FDU36	3.67	1.006	-0.420	-0.194
EIA4	3.75	1.074	-0.629	-0.212	AHA37	3.33	1.100	-0.274	-0.578
EIA5	3.59	1.114	-0.480	-0.435	AHA38	3.48	1.080	-0.474	-0.269
EIA6	3.94	1.025	-0.826	0.222	AHA39	3.39	1.064	-0.297	-0.418
EIA7	3.81	1.079	-0.677	-0.230	AHA40	3.37	1.080	-0.303	-0.421
EIA8	3.99	0.976	-0.862	0.406	AHA41	3.53	1.007	-0.458	-0.054
MDA9	3.88	1.050	-0.734	-0.084	AHA42	3.63	1.038	-0.492	-0.195
MDA10	3.50	1.090	-0.383	-0.387	AHA43	3.70	1.010	-0.606	-0.012
MDA11	4.00	0.991	-1.016	0.796	RIA44	3.53	1.102	-0.370	-0.463
MDA12	4.01	1.628	14.453	360.641	RIA45	3.56	1.061	-0.373	-0.337
MDA13	4.04	1.014	-1.162	1.103	RIA46	3.59	1.004	-0.413	-0.101
MDA14	3.85	1.017	-0.730	0.108	RIA47	3.68	1.054	-0.532	-0.230
MDA15	3.35	1.114	-0.283	-0.516	RIA48	3.58	1.020	-0.434	-0.178
MDA16	3.95	1.016	-0.981	0.656	RIA49	3.68	1.090	-0.494	-0.465
MDA17	3.37	1.118	-0.222	-0.573	PIA50	3.22	1.041	-0.073	-0.381
DCT18	2.53	1.214	0.479	-0.649	PIA51	3.43	0.983	-0.213	-0.270
DCT19	2.46	1.122	0.511	-0.359	PIA52	3.48	0.939	-0.294	-0.112
DCT20	2.27	1.094	0.694	-0.126	PIA53	3.21	0.918	-0.003	0.008
DCT21	2.31	1.140	0.626	-0.392	PIA54	3.37	0.965	-0.106	-0.087
DCT22	2.04	1.165	0.984	0.069	PIA55	3.32	0.979	-0.187	-0.164
DCT23	2.42	1.177	0.496	-0.588	PIA56	3.47	0.993	-0.287	-0.239



DCT24	2.34	1.156	0.581	-0.432	AIA57	2.42	1.178	0.516	-0.456
DCT25	2.11	1.190	0.904	-0.090	AIA58	2.27	1.151	0.704	-0.249
DCT26	2.25	1.217	0.679	-0.505	AIA59	2.57	1.197	0.353	-0.710
DCT27	2.51	1.226	0.425	-0.766	AIA60	2.41	1.188	0.528	-0.547
DCT28	2.56	1.186	0.328	-0.674	PDE61	3.55	1.163	-0.440	-0.588
FDU29	3.32	1.071	-0.118	-0.527	PDE62	3.63	1.086	-0.469	-0.344
FDU30	3.75	1.077	-0.555	-0.456	PDE63	3.33	1.070	-0.173	-0.414
FDU31	3.98	0.979	-0.847	0.391	PDE64	3.34	1.160	-0.151	-0.647
FDU32	3.81	0.983	-0.584	-0.033	PDE65	3.58	1.082	-0.386	-0.362
FDU33	3.80	1.135	-0.748	-0.207	PDE66	3.00	1.249	0.000	-0.872

EIA = Efectividad de uso de la IA; MDA = Mejoras de aprendizaje; DCT = Dependencia cognitiva y tecnológica; FDU = Facilidad de uso; AHA = Apoyo hacia el aprendizaje; RIA = Reacciones emocionales hacia la IA; PIA = Precisión de la IA; AIA = Aversión hacia el uso de la IA; PDE = Percepción docente.

Fuente: Elaboración propia

Por consiguiente, todos los ítems muestran normalidad univariada en sus puntajes, con excepción del ítem MDA12, el cual presenta valores de asimetría y curtosis por encima de +10.

Por otro lado, el ítem PIA53 fue el que presentó menor variabilidad en sus opciones de respuesta (alrededor de las opciones tres y cuatro), al tener la menor desviación estándar (0.91), con media de 3.21. Por su parte, el ítem MDA12 fue el de mayor variabilidad (alrededor de las opciones tres y cuatro), al obtener la desviación estándar más alta (1.62), alrededor de la media de 4.01.

Análisis de fiabilidad

Para la confiabilidad de las subescalas, se realizó la prueba de alfa de Cronbach empleando el software SPSS® versión 25 (Ver tabla 2). Se aprecia que el valor del alfa de Cronbach global de las nueve escalas fue alto (0.947).



Tabla 2*Alfa de Cronbach de las dimensiones y global del instrumento PEIIA*

Dimensiones	Número de ítems	Alfa de Cronbach
Efectividad de uso de la IA	8	0.889
Mejoras de aprendizaje	9	0.878
Dependencia cognitiva y tecnológica	11	0.917
Facilidad de uso	8	0.851
Apoyo hacia el aprendizaje	7	0.897
Reacciones emocionales hacia la IA	6	0.851
Precisión de la IA	7	0.871
Aversión hacia el uso de la IA	4	0.870
Percepción docente	6	0.722
Total	66	0.947

Fuente: Elaboración propia

Análisis factorial exploratorio

Se realizó un AFE deductivo, con un método de extracción de componentes principales con rotación Varimax, empleando el software estadístico SPSS en su versión 25. El criterio de exclusión fue aquellos ítems con cargas factoriales menores a 0.30 y aquellos que presentaban cargas mayores a este valor en dos factores (DeVellis, 2012). Para el caso de la subescala de Efectividad de uso de la IA (EIA), el índice Kaiser, Meyer y Olkin (KMO) fue muy notable, de 0.92, y la prueba de esfericidad de Bartlett resultó significativa ($X^2= 3671.76$, $p < 0.000$). Se obtuvo que una solución de dos factores que explicó 66.2% de la varianza total de los puntajes.

El KMO de la subescala de Mejoras de aprendizaje (MDA) fue muy notable al alcanzar un valor de 0.91, y la prueba de esfericidad de Bartlett resultó significativa ($X^2= 3994.31$, $p < 0.000$). Se obtuvo una solución con dos factores que explican 62.3% de la varianza total de los puntajes. Para la subescala de Dependencia cognitiva y tecnológica (DCT) el KMO fue muy notable de 0.93, y la prueba de esfericidad de Bartlett resultó significativa ($X^2= 6235.23$, $p < 0.000$). Se obtuvo una solución de dos factores que resulta 63.8% de la varianza total de los puntajes. En el caso de la subescala de Facilidad



de uso (FDU), el KMO fue notable de 0.84, y la prueba de esfericidad de Bartlett resultó significativa ($X^2= 3207.02$, $p < 0.000$). Arrojó una solución con dos factores que refiere 63.4% de la varianza total de los puntajes.

Para la subescala de Apoyo hacia el aprendizaje (AHA) se calculó nuevamente el KMO, que resultó notable al llegar a 0.89, y la prueba de esfericidad de Bartlett una vez más resultó significativa ($X^2= 3731.79$, $p < 0.000$). La reducción de términos se obtuvo con dos factores que logran explicar 71.9% de la varianza total de los puntajes. El KMO de la subescala Reacciones emocionales hacia la IA (RIA) fue notable al alcanzar un valor de 0.87, y la prueba de esfericidad de Bartlett resultó significativa ($X^2= 2443.39$, $p < 0.000$). Se obtuvo una solución con dos factores que explican 71.9% de la varianza total de los puntajes. Para la subescala de Precisión de la IA (PIA) el KMO fue notable de 0.88, y la prueba de esfericidad de Bartlett resultó significativa ($X^2= 3090.24$, $p < 0.000$). Se obtuvo una solución de dos factores que resulta 69.0% de la varianza total de los puntajes.

Para la subescala de Aversión hacia el uso de la IA (AIA) el KMO fue notable de 0.82, y la prueba de esfericidad de Bartlett resultó significativa ($X^2= 1957.42$, $p < 0.000$). Se obtuvo una solución de dos factores que resulta 83.2% de la varianza total de los puntajes. En el caso de la subescala de Percepción docente (PDE) se calculó nuevamente el KMO, que resultó normal al llegar a 0.74, y la prueba de esfericidad de Bartlett una vez más resultó significativa ($X^2= 1287.33$, $p < 0.000$). La reducción de términos se obtuvo con dos factores que logran explicar 61.5% de la varianza total de los puntajes (Ver Tabla 3).



Tabla 3

Resultados del AFE de las subescalas que componen el cuestionario Percepciones de los estudiantes hacia la incorporación de IA

Escala	KMO	X ²	gl	X ² /gl	% de var	factores	ítems
EIA	0.92	3671.76	28	131.13	66.2%	2	8
MDA	0.91	3994.31	36	110.95	62.3%	2	9
DCT	0.93	6235.23	55	113.36	63.8%	2	11
FDU	0.84	3207.02	28	114.53	63.4%	2	8
AHA	0.89	3731.79	21	177.70	71.9%	2	7
RIA	0.87	2443.39	15	162.89	71.9%	2	6
PIA	0.88	3090.24	21	147.15	69.0%	2	7
AIA	0.82	1957.42	6	326.23	83.2%	2	4
PDE	0.74	1287.33	15	85.82	61.5%	2	6

Nota. EIA = Efectividad de uso de la IA; MDA = Mejoras de aprendizaje; DCT = Dependencia cognitiva y tecnológica; FDU = Facilidad de uso; AHA = Apoyo hacia el aprendizaje; RIA = Reacciones emocionales hacia la IA; PIA = Precisión de la IA; AIA = Aversión hacia el uso de la IA; PDE = Percepción docente.

Fuente: Elaboración propia

Análisis factorial confirmatorio (AFC)

A fin de corroborar la asociación de factores obtenida en el AFE, se llevó a cabo el AFC tomando como criterio base la teoría del instrumento y los análisis factoriales congruentes con el diseño de las subescalas. Además, se consideró el mínimo de tres ítems por factor. Para tal fin, se empleó el método de estimación de máxima verosimilitud para determinar la bondad de ajuste empírica del modelo.

Como resultado del AFC, se eliminaron los ítems que no se asociaron con los factores del modelo (Byrne, 2010; Cea, 2004). De esta forma, se obtuvieron los modelos de medida por cada escala que cumplieron con los índices de bondad de ajuste, a fin de confirmar la sustentabilidad empírica del modelo. Los índices considerados fueron: el índice χ^2 al cuadrado sobre grados de libertad o relativa (X^2 /gl), la raíz cuadrada de residual estandarizada (SRMR), el índice de bondad de ajuste ajustado



(AGFI), el índice de ajuste comparativo (CFI) y, finalmente, el error de la raíz cuadrada de la media de aproximación (RMSEA). Estos índices se consideran aceptables si sus valores superan los criterios de ajuste establecidos, que son ($X^2/gl > 1$; CFI y AGFI > 0.95 ; SRMR < 0.08 y RMSEA < 0.06 (Brown, 2015; Hooper, Coughlan y Mullen, 2008; Hu y Bentler, 1999;). A continuación, se presentan los resultados obtenidos en los índices de bondad de ajuste para cada una de las subescalas (ver Tabla 4).

Tabla 4

Índices de los modelos para medir las subescalas del cuestionario Percepciones de los estudiantes hacia la incorporación de IA

Modelo	Chi-	gl	X ²	CFI	SRMR	RMSEA	AGFI
	cuadrado		relativa				
	X ²		(X ² /gl)				
EIA	104.805	19	5.516	.977	.027	.067*	.974
MDA	3.678	2	1.839	.999	.009	.029	.991
DCT	8.883	2	4.441	.994	.014	.058	.979
FDU	15.650	4	3.913	.990	.019	.054	.977
AHA	9.834	4	2.459	.997	.011	.038	.985
RIA	13.346	5	2.669	.996	.013	.041	.985
PIA	19.379	2	9.690	.990	.018	.093*	.950
PDE	8.317	4	2.079	.996	.015	.033	.988

Nota. EIA = Efectividad de uso de la IA; MDA = Mejoras de aprendizaje; DCT = Dependencia cognitiva y tecnológica; FDU = Facilidad de uso; AHA = Apoyo hacia el aprendizaje; RIA = Reacciones emocionales hacia la IA; PIA = Precisión de la IA; PDE = Percepción docente.

*Marca los índices que no cumplen con los criterios de bondad de ajuste del modelo.

Fuente: Elaboración propia

Igualmente como resultado del AFC, se obtiene que las subescalas MDA, DCT, FDU, AHA, RIA y PDE son las únicas validadas por la totalidad de sus índices de bondad de ajuste. Mientras tanto, en las escalas EIA y PIA no se satisfacen los criterios de ajuste en uno de sus índices, el RMSEA, lo cual se desestima, ya que se pueden considerar validadas por sus cuatros índices restantes.

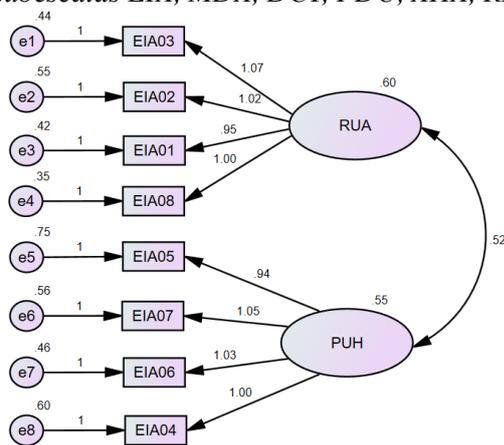


Una vez validadas las escalas, se presentan sus respectivos modelos de medida, de los cuales los correspondientes a las subescalas MDA, DCT, RIA y PIA, contemplan un modelo unidimensional, el resto de ellos resultaron modelos de dos factores, con al menos dos variables observables por componente.

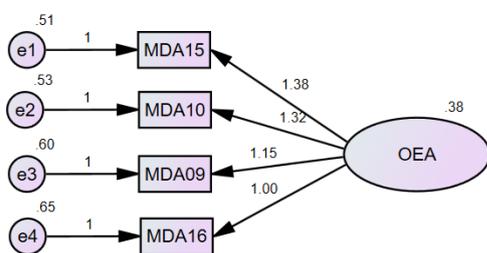
Por lo tanto, para la subescala MDA se llegó a un modelo de 4 ítems (MDA15, MDA10, MDA9 y MDA16). En el caso de la subescala DCT se llegó a un modelo de 4 ítems (DCT24, DCT26, DCT18 Y DCT19). Por otro lado, en el caso de la subescala RIA, se llegó a un modelo de 5 ítems (RIA48, RIA49, RIA44, RIA47 y RIA4). Por último, para la subescala PIA se llegó a un modelo de 4 ítems (PIA50, PIA51, PIA52 y PIA53) (ver Figura 1).

Figura 1

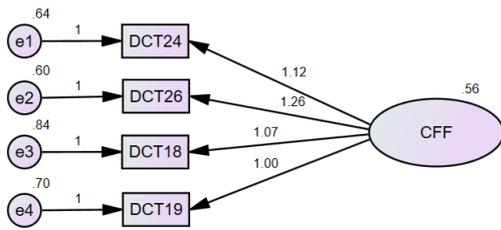
Modelos de medida de la escala Percepciones de los estudiantes hacia la incorporación de IA (subescalas EIA, MDA, DCT, FDU, AHA, RIA, PIA y PDE)



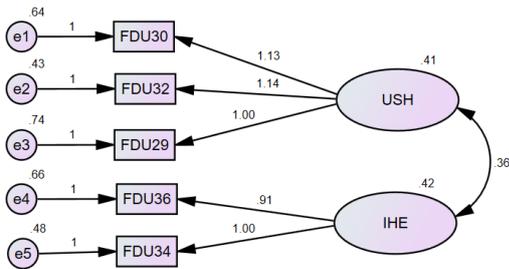
Modelo de medida para la subescala EIA



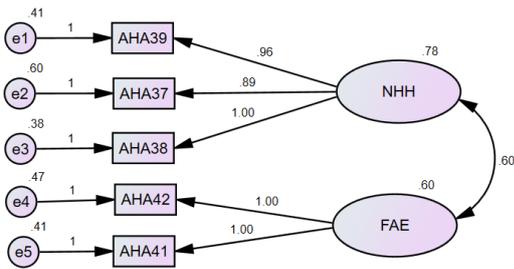
Modelo de medida para la subescala MDA



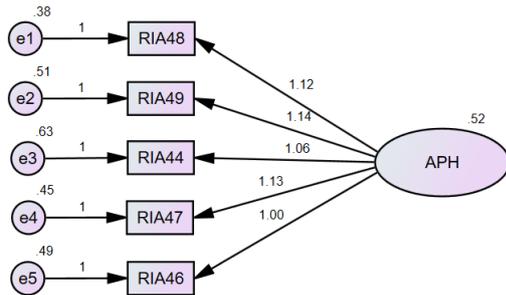
Modelo de medida para la subescala DCT



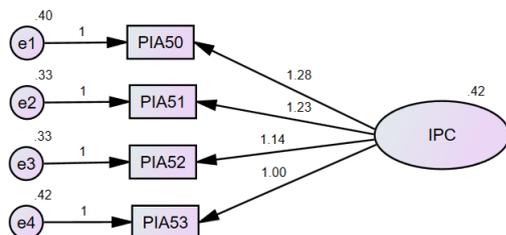
Modelo de medida para la subescala FDU



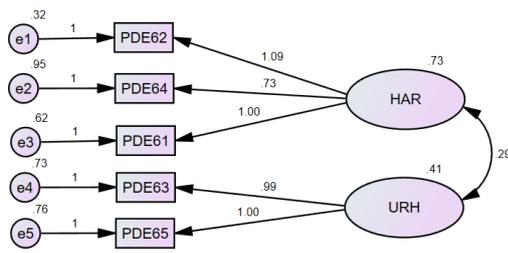
Modelo de medida para la subescala AHA



Modelo de medida para la subescala RIA



Modelo de medida para la subescala PIA



Modelo de medida para la subescala PDE

Fuente: Elaboración propia

Discusión

El proceso de validez y confiabilidad relatado da cuenta de los hallazgos encontrados acerca de la escala PEIIA, con un Alfa de Cronbach de 0.947 y un índice KMO de 0.958 en las nueve subescalas que comprende, lo cual permite afirmar la comprobación de la hipótesis planteada, por lo que se puede emplear en estudiantes universitarios para conocer las percepciones de los alumnos hacia la incorporación de Inteligencia Artificial en el ámbito educativo. Destaca como fortaleza la integración de las subescalas que la conforman.

CONCLUSIONES

Tras el análisis de las propiedades métricas de la escala PEIIA, se excluyó la subescala PDE al tener un alfa de Cronbach de 0.722, ligeramente por debajo del umbral recomendado (≥ 0.7). En la subescala MDA se excluyó el constructo Actividades con las Herramientas (ACS) por carecer de indicadores adecuados.

Por otra parte, en la subescala DCT se excluyó el constructo Impacto Negativo en el Aprendizaje (INA) por carecer de indicadores adecuados. En la subescala RIA se excluyó el constructo Reducción del Esfuerzo Necesario (REN) por carecer de indicadores adecuados. Por otro lado, en la subescala PIA se excluyó el constructo Proporciona Soluciones Efectivas (PSE) por carecer de indicadores adecuados.

Finalmente, sobre la subescala de AIA, que buscaba identificar dos constructos, se excluyó primeramente el de Herramienta para distracción en el estudio (HDE) por carecer de indicadores adecuados. Para el constructo restante, Efectos de la Tecnología de desconfianza y frustración (GDF),



se realizó un modelo unifactorial en el AFC; sin embargo, se decidió excluir la subescala de la escala PEIIA al nuevamente carecer de indicadores adecuados.

En cuanto a la confiabilidad, el alfa de Cronbach global de las siete subescalas fue muy alto (0.945), lo que indica que, en su conjunto, las subescalas miden el constructo para el cual fueron creadas, de modo que la escala PEIIA permite conocer las percepciones de los estudiantes a nivel universitario hacia la incorporación de Inteligencia Artificial en el ámbito educativo. Tras los análisis aquí presentados, la escala queda conformada por siete factores y 35 ítems.

De manera general, en las siete subescalas que conforman el instrumento se encontraron algunas oportunidades de mejora para obtener la evidencia empírica necesaria para sostener los constructos que se buscan identificar. Con lo anterior, se comprueba la hipótesis inicial, y se concluye que la escala PEIIA posee niveles aceptables de confiabilidad para medir las percepciones de los estudiantes a nivel universitario hacia la incorporación de Inteligencia Artificial en el ámbito educativo. Sería conveniente realizar una nueva aplicación con estudiantes de otras áreas de formación o de otros estados de México o países, además probar con estudiantes de nivel bachillerato o de posgrado. Lo que permitirá una mayor perspectiva y a su vez hacer una segunda validación del instrumento en otra población de estudio.

La inteligencia artificial está reconfigurando la educación superior, presentando tanto oportunidades transformadoras como desafíos complejos. Para navegar eficazmente este nuevo panorama, es indispensable comprender en profundidad cómo los estudiantes universitarios interactúan con la IA, qué piensan y sienten al respecto, qué competencias poseen y cómo el entorno institucional y pedagógico influye en sus prácticas.

Es necesario que las instituciones de educación superior tomen decisiones informadas sobre políticas, diseño curricular, formación docente y apoyo estudiantil, con el fin último de aprovechar el potencial de la IA para mejorar el aprendizaje y preparar a los estudiantes para un futuro cada vez más digitalizado, garantizando al mismo tiempo un uso ético, equitativo y centrado en el ser humano.

REFERENCIAS BIBLIOGRÁFICAS

Aliño, J., Rebato, A., Abrenica, A., Baguio, J., Villanueva, M., Dianne, O. y Sumatra, K. (2024). The Relationship Between AI Self-Efficacy and AI Trust of College Students. *International Journal of Multidisciplinary Studies in Higher Education*, 1(1), 92–102.



<https://doi.org/10.70847/587961>

- Alshamy, A., Al-Harhi, A. y Abdullah, S. (2025). Perceptions of Generative AI Tools in Higher Education: Insights from Students and Academics at Sultan Qaboos University. *Education Sciences*, 15(4), 501-516. <https://doi.org/10.3390/educsci15040501>
- Brown, T. (2015). *Confirmatory Factor Analysis for Applied Research* (2ª edición). The Guilford Press.
- Byrne, B. (2010). *Structural Equation Modeling with AMOS* (2ª edición). Routledge Taylor & Francis Group.
- Cao, Y., Aziz, A. y Arshard, W. (2023). University students' perspectives on Artificial Intelligence: A survey of attitudes and awareness among Interior Architecture students. *IJERI: International Journal of Educational Research and Innovation*, (20), 1–21. <https://doi.org/10.46661/ijeri.8429>
- Cea, M. (2004). *Análisis multivariable. Teoría y práctica en la investigación social*. Síntesis.
- Chávez, G., Polo, T., Zegarra, L., Balarezo, O., Calderón, C. y Dominguez, S. (2024). Self-efficacy scale for university teaching in virtual environments, SSUTVE. *Heliyon*, 11(1), 1-25. <https://doi.org/10.1016/j.heliyon.2024.e41134>
- Cruz, J., Villafranca, F. y Taype, O. (2024). Revolucionando el aprendizaje: El papel de la inteligencia artificial en la educación universitaria. *Revista Tribunal*, 4(9), 525-540. <https://doi.org/10.59659/revistatribunal.v4i9.81>
- De Lara, A. (2022). Retos de la divulgación de la inteligencia artificial en los cibermedios españoles. *Contratexto*, 38(038), 205-226. <https://doi.org/10.26439/contratexto2022.n038.5701>
- DeVellis, R. (2012). *Scale Development. Theory and Applications*. SAGE.
- Gallent, C., Zapata, A. y Ortego, J. (2023). El impacto de la inteligencia artificial generativa en educación superior: una mirada desde la ética y la integridad académica. *RELIEVE. Revista Electrónica de Investigación y Evaluación Educativa*, 29(2), 1-21. <https://doi.org/10.30827/relieve.v29i2.29134>
- García, D., Cobo, R. y Hernández, J. (2022). Validez, fiabilidad e invarianza factorial de las escalas de autoeficacia general y autoeficacia académica en estudiantes universitarios. *Retos*, 46, 1093–1104. <https://doi.org/10.47197/retos.v46.94281>



- Griffin, M. y Steinbrecher, T. (2013). Large-Scale Datasets in Special Education Research. En R. Urbano (ed.), *International Review of Research in Developmental Disabilities* (Vol. 45, pp. 155-183). Elsevier. <https://doi.org/10.1016/b978-0-12-407760-7.00004-9>
- Hooper, D., Coughlan, J. y Mullen, M. (2008). Structural Equation Modelling: Guidelines for Determining Model Fit. *Electronic Journal of Business Research Methods*, 6(1), 53-60. https://www.researchgate.net/publication/254742561_Structural_Equation_Modeling_Guidelines_for_Determining_Model_Fit
- Hu, L. y Bentler, P. (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>
- Katsantonis, A. y Katsantonis, I. (2024). University Students' Attitudes toward Artificial Intelligence: An Exploratory Study of the Cognitive, Emotional, and Behavioural Dimensions of AI Attitudes. *Education Sciences*, 14(9), 988-1001. <https://doi.org/10.3390/educsci14090988>
- Khairuddin, Z., Shahabani, N., Ahmad, S., Ahmad, A. y Zamri, N. (2024). Students' Perceptions on The Artificial Intelligence (AI) Tools As Academic Support. *Malaysian Journal of Social Sciences and Humanities (MJSSH)*, 9(11), 1-13. <https://doi.org/10.47405/mjssh.v9i11.3087>
- Kline, R. (2016). *Principles and Practice of Structural Equation Modeling* (4ª edición). The Guilford Press.
- Larico, R. (2024). Impacto de la inteligencia artificial generativa ChatGPT en la enseñanza universitaria. *Chakiñan, Revista De Ciencias Sociales Y Humanidades*, (25), 317-341. <https://doi.org/10.37135/chk.002.25.14>
- Narváez, R. y Medina, L. (2024). Validación de un cuestionario para explorar el uso de la IA en estudiantes de educación superior. *Revista Paraguaya de Educación a Distancia (REPED)*, 5(4), 29-40. <https://doi.org/10.56152/reped2024-dossierIA2-art4>
- Negrete, M. y Mosquera, D. (2025). Estrategias Didácticas Basadas en Inteligencia Artificial para el Aprendizaje del Inglés: Una Revisión Sistemática de la Producción Bibliográfica 2019-2023. *Ciencia Latina Revista Científica Multidisciplinar*, 9(1), 4538-4560. https://doi.org/10.37811/cl_rcm.v9i1.16172



- Osman, Z. (2025). Attitude as a Catalyst: The Role of Perceived Ease of Use, Perceived Usefulness, and Self-Efficacy in Shaping Student Intentions to Use Artificial Intelligence in Higher Education. *International Journal of Academic Research in Accounting, Finance and Management Sciences*, 15(1), 201–215. <http://dx.doi.org/10.6007/IJARAFMS/v15-i1/24459>
- Slimi, Z. (2023). The Impact of Artificial Intelligence on Higher Education: An Empirical Study. *ERIC. European Journal of Educational Sciences*, 10(1), 17-33. <http://dx.doi.org/10.19044/ejes.v10no1a17>
- Swidan, A., Lee, S. y Romdhane, S. (2025). College Students' Use and Perceptions of AI Tools in the UAE: Motivations, Ethical Concerns and Institutional Guidelines. *Education Sciences*, 15(4), 461-481. <https://doi.org/10.3390/educsci15040461>
- Vera, P., Bonilla, G., Quishpe, A. y Campos, H. (2023). La inteligencia artificial en la educación superior: un enfoque transformador. *Polo del Conocimiento*, 8(11), 67-80. <https://polodelconocimiento.com/ojs/index.php/es/article/view/6193>
- Wang, Y y Chuang, Y. (2024). Artificial intelligence self-efficacy: Scale development and validation. *Education and Information Technologies*, 29, 4785–4808. <https://doi.org/10.1007/s10639-023-12015-w>
- Yurt, E. y Kasarci, I. (2024). A Questionnaire of Artificial Intelligence Use Motives: A contribution to investigating the connection between AI and motivation. *International Journal of Technology in Education (IJTE)*, 7(2), 308-325. <https://doi.org/10.46328/ijte.725>

