

Tito

Informe-ARTICULO-FINAL.docx

 Universidad Peruana Union

Detalles del documento

Identificador de la entrega

trn:oid:::29566:477384514

Fecha de entrega

30 jul 2025, 2:56 p.m. GMT-5

Fecha de descarga

30 jul 2025, 3:02 p.m. GMT-5

Nombre de archivo

Informe-ARTICULO-FINAL.docx

Tamaño de archivo

871.1 KB

20 Páginas

6491 Palabras

37.193 Caracteres

13% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- Bibliografía
- Texto citado
- Coincidencias menores (menos de 8 palabras)

Exclusiones

- N.º de fuentes excluidas

Fuentes principales

- 9%  Fuentes de Internet
- 5%  Publicaciones
- 10%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

Fuentes principales

- 9% Fuentes de Internet
- 5% Publicaciones
- 10% Trabajos entregados (trabajos del estudiante)

Fuentes principales

Las fuentes con el mayor número de coincidencias dentro de la entrega. Las fuentes superpuestas no se mostrarán.

1	Internet	sedici.unlp.edu.ar	<1%
2	Internet	incomchile.cl	<1%
3	Internet	retosdelacienciaec.com	<1%
4	Internet	es.scribd.com	<1%
5	Trabajos entregados	Fundación Universitaria del Area Andina on 2025-05-29	<1%
6	Trabajos entregados	Universidad Rey Juan Carlos on 2025-06-05	<1%
7	Publicación	Claudio José Hidalgo Vargas, Jessica Katherine Gaona Alvarado, Ana Lucia Hidalg...	<1%
8	Trabajos entregados	IBERO: Universidad Iberoamericana Ciudad de Mexico on 2024-08-15	<1%
9	Trabajos entregados	Universidad Internacional de la Rioja on 2024-11-12	<1%
10	Trabajos entregados	Universidad de Guayaquil on 2025-07-22	<1%
11	Internet	alicia.concytec.gob.pe	<1%

12	Publicación	Inés Aramburu, Manel Salamero, Berta Aznar, Carles Pérez-Testor, Montse Davins...	<1%
13	Publicación	Allison Squires, Jason Fletcher, Hortensia Castañeda Hidalgo, Gustavo Nigenda. "...	<1%
14	Trabajos entregados	Universidad Cesar Vallejo on 2024-01-30	<1%
15	Internet	dialnet.unirioja.es	<1%
16	Internet	edulab.es	<1%
17	Trabajos entregados	Universidad Internacional de la Rioja on 2024-06-02	<1%
18	Trabajos entregados	Universidad Anahuac México Sur on 2025-03-29	<1%
19	Internet	revistascientificas.una.py	<1%
20	Trabajos entregados	Universidad Internacional de la Rioja on 2025-05-21	<1%
21	Trabajos entregados	Universidad de Málaga - Tii on 2024-02-23	<1%
22	Internet	www.cienciayeducacion.com	<1%
23	Publicación	Alba Moya-Garófano, Jesús L. Megías, Rosa Rodríguez-Bailón, Miguel Moya. "Span...	<1%
24	Publicación	Ana-Belén López-Cámara, Ignacio González-López, Carlota de León-Huertas. "Expl...	<1%
25	Publicación	Ilham Ilham, Muliya Safitri, Anton Komaini, Nurul Ihsan, Bekir Erhan Orhan, Vlad ...	<1%

26	Trabajos entregados	Universidad Estatal Amazonica- on 2025-07-12	<1%
27	Trabajos entregados	Universidad Rey Juan Carlos on 2024-05-18	<1%
28	Internet	adayapress.com	<1%
29	Internet	dilemascontemporaneoseduacionpoliticayvalores.com	<1%
30	Internet	revistas.ult.edu.cu	<1%
31	Trabajos entregados	ITESM: Instituto Tecnologico y de Estudios Superiores de Monterrey on 2025-02-14	<1%
32	Publicación	Raimundo Olfos, Palmenia Rodríguez. "Contribution of teacher knowledge to stu...	<1%
33	Trabajos entregados	Universidad Anahuac México Sur on 2023-10-23	<1%
34	Trabajos entregados	Universidad Católica de Santa María on 2025-01-17	<1%
35	Trabajos entregados	Universidad de Nebrija on 2025-05-23	<1%
36	Internet	asamblea.racsa.co.cr	<1%
37	Internet	www.scielo.org.co	<1%
38	Internet	www.scielo.sa.cr	<1%
39	Publicación	Alonso-Arbiol, Itziar, Nekane Balluerka, Arantxa Gorostiaga, Aitor Aritzeta, Miria...	<1%

40	Publicación	Javier Palacios Fenech. "The diffusion of new products in Latin America: a new co...	<1%
41	Trabajos entregados	Universidad Simón Bolívar, Colombia on 2025-04-26	<1%
42	Trabajos entregados	Universidad de Nebrija on 2025-06-03	<1%
43	Internet	cienciasmarinas.com.mx	<1%
44	Internet	eprints.ucm.es	<1%
45	Internet	gaceta.cicese.mx	<1%
46	Internet	repositorio.uasb.edu.ec	<1%
47	Trabajos entregados	ucol on 2023-10-10	<1%
48	Internet	www.cienciadedatos.net	<1%
49	Internet	www.frontiersin.org	<1%
50	Internet	zagan.unizar.es	<1%
51	Trabajos entregados	Caribbean University on 2023-08-03	<1%
52	Publicación	Cristina Rodríguez, Juan E. Jiménez. "What cognitive and numerical skills best defi...	<1%
53	Publicación	R. C. Reis, A. M. Ramos, A. J. Regazzi, V. P. R. Minim, P. C. Stringueta. "ALMACENAM...	<1%

54	Publicación	Rita B. Domingues, Jacinta Fernandes, Maria Cabral, Gabriela Gonçalves. "Psycho...	<1%
55	Trabajos entregados	Universidad Metropolitana de Educación, Ciencia y Tecnología on 2025-06-30	<1%
56	Trabajos entregados	Universidad de Salamanca on 2021-11-13	<1%
57	Internet	archive.org	<1%
58	Internet	datospdf.com	<1%
59	Internet	docplayer.es	<1%
60	Internet	es.slideshare.net	<1%
61	Internet	infonomy.scimagoepi.com	<1%
62	Internet	institutojubones.edu.ec	<1%
63	Internet	moam.info	<1%
64	Internet	novascientia.delasalle.edu.mx	<1%
65	Internet	produccioncientificaluz.org	<1%
66	Internet	repositorio.upse.edu.ec	<1%
67	Internet	technologyrain.com.ar	<1%

68	Trabajos entregados ucol on 2024-12-02	<1%
69	Internet www.ctes.org.mx	<1%
70	Internet www.mysciencework.com	<1%
71	Internet www.revistacomunicar.com	<1%

Adecuación y Validación de un cuestionario sobre uso de la Inteligencia Artificial en la enseñanza de la Matemática en docentes peruanos de nivel secundario

1 Edgar Tito Susanibar Ramirez¹, Javier Linkolk López Gonzales¹

2 ¹Escuela de Posgrado, Universidad Peruana Unión, Lima, Perú

3 * **Correspondence:**

4 Corresponding Author

5 linkolklg@upeu.edu.pe

6 **Keywords:** Inteligencia artificial₁, enseñanza de matemáticas₂, Adaptación₃, validación₄,
7 cuestionario₅.

8 **Resumen**

9 El presente estudio realiza un análisis del empleo de instrumentos para el uso de la inteligencia
10 artificial en el campo educativo, tiene por finalidad adaptar y validar un cuestionario con relación al
11 uso de la Inteligencia Artificial en la enseñanza de las Matemáticas en docentes peruanos de nivel
12 secundario. Para ello, se aplica una revisión bibliográfica exhaustiva, permitiendo determinar que no
13 se cuenta con un instrumento validado como tal para el caso peruano. Se ha traducido y adaptado un
14 instrumento validado en Jordania, realizándose un proceso de validación para el caso del Perú. La
15 muestra para realizar el análisis exploratorio estuvo formada por 150 docentes peruanos del nivel
16 secundario que enseñan matemáticas en la educación básica, y posteriormente se encuestó a 266
17 docentes para el realizar análisis factorial. Fueron encuestados desde noviembre del 2024 hasta
18 marzo del 2025 mediante el formulario de Google. Los resultados dan cuenta que hemos logrado
19 adaptar y validar un cuestionario para medir el nivel de los docentes de matemáticas en el empleo de
20 Aplicaciones de la Inteligencia Artificial en el Proceso Educativo para el caso peruano, obteniéndose
21 un coeficiente de Aiken moderado o alto en casi todos los ítems a excepción de tres ítems y además
22 un coeficiente de consistencia interna alfa de Cronbach 0.96. Asimismo, se ha logrado realizar un
23 análisis exploratorio obteniéndose un índice KMO de 0.95, determinándose que el instrumento puede
24 ser de tipo bidimensional para el caso peruano. Estos resultados con complementarios a los estudios

25 realizado previamente en Jordania y permite contar con un instrumento validado para medir el nivel
26 de los docentes de matemáticas en el empleo de Aplicaciones de la Inteligencia Artificial en el
27 Proceso Educativo en el Perú. En el análisis confirmatorio de obtiene un modelo ajustado con
28 estimación por máxima verosimilitud, aunque el estadístico Chi-cuadrado ($\chi^2 = 926.594$, $p < .001$)
29 indica un ajuste imperfecto, este resultado debe interpretarse con cautela, porque los índices de ajuste
30 comparativo CFI = 0.808 y TLI = 0.783, se sitúan por debajo del umbral óptimo de 0.90, sugiriendo
31 un ajuste moderado. El RMSEA fue de 0.148 (IC90%: 0.140–0.158), con un p-valor $< .001$ para H_0 :
32 $RMSEA \leq 0.05$, indicando una discrepancia notable entre el modelo y los datos. El SRMR alcanzó
33 0.394, superando también el valor deseado (< 0.08).

34 Actualmente en Latinoamérica los estudiantes usan con relativa frecuencia la inteligencia artificial
35 generativa (IA) (Ríos Hernández et al.2024). En Perú, de la misma forma los estudiantes utilizan la
36 IA (Gálvez Marquina et al., 2024) y (Sevilla y Barrios, 2024). La IA ha revolucionado todas las áreas
37 del conocimiento, pero de manera pertinente en la educación se ha implementado en todos los niveles
38 educativos con experiencias favorables (Gallent-Torres et al., 2024) y (Esteves Fajardo et al., 2024).

39 En los recientes años se han desarrollado algunos instrumentos que tengan la finalidad de medir las
40 actitudes de los estudiantes hacia la IA (Grassini, 2023). Alissa y Hamadneh (2023), en Jordania
41 desarrollaron un cuestionario que consta de 22 ítems para medir el nivel de uso de la IA en la enseñanza
42 de las ciencias y matemáticas, sus resultados muestran un nivel moderado de uso de aplicaciones de
43 inteligencia artificial por parte de los profesores de ciencias y matemáticas. Ng et al.(2024),
44 desarrollaron y validaron en Hong Kong un instrumento de alfabetización de la IA (AILQ), un
45 autoinforme que mide como los estudiantes de secundaria desarrollan y perciben sus resultados de
46 aprendizaje. Los resultados indicaron una estructura de cuatro factores del AILQ y revelaron una buena
47 confiabilidad y validez. Montoya Asprilla (2024) en Colombia desarrollaron una investigación
48 respecto a las percepciones y actitudes hacia la integración de la IA, concluyeron que los docentes
49 poseen conocimiento moderados de la IA. Grassini (2023) desarrolló y validó en Noruega una escala
50 de actitudes hacia la IA (AIAS), un instrumento sencillo de autoinforme con 4 ítems desarrollado y
51 validado para los investigadores y profesionales que trabajan en el desarrollo de IA. Marango
52 et al.(2024) desarrollan y validan en Italia una escala para evaluar las actitudes de los estudiantes
53 universitarios hacia el uso de la IA como ChatGPPT en entornos educativos. De la misma forma se
54 tiene un cuestionario TRACK validado en España para evaluar los conocimientos tecnológicos,
55 pedagógico y disciplinar del profesorado, presenta estructura factorial optima, satisfactorios niveles de

56 confiabilidad y una validez (Saz-Pérez et al., 2024). Finalmente Rodríguez-Gutiérrez et al.(2024)
57 validaron en México un cuestionario que tiene 12 factores y 48 ítems para medir la aceptación de
58 tecnologías inteligentes entre los estudiantes de la generación Z.

59 Algunos autores como Alissa y Hamadneh (2023), Opesemowo y Adewuyi (2024), Andrade-Girón
60 et al (2024), Silva et al.(2024), Wang et al. (2025) y Panqueban y Huincahue (2024) sugieren
61 realizar más investigaciones respecto a los usos y la validación de los atributos de la IA. El uso de la
62 IA en la enseñanza aprendizaje se hace exitoso (Vankúš, 2024). Por otro lado, en nuestro medio se
63 tiene poca bibliografía de instrumentos validados para evaluar el uso de las herramientas tecnologías
64 con inteligencia artificial (Nemt-allah et al., 2024) y (Ng et al., 2024), particularmente en el
65 desarrollo de las capacidades matemáticas (Bejarano y Guerrero, 2021).

66 Por consiguiente, este trabajo pretende validar un cuestionario respecto uso de la Inteligencia
67 Artificial adaptado a la enseñanza de las Matemáticas en docentes peruanos de nivel secundario.

68 Revisión de la Literatura

69 La Inteligencia artificial es la herramienta tecnológica desarrollada por empresas privadas que captan
70 y analizan datos mediante algoritmos que simulan la inteligencia humana (Gálvez et al., 2024) y
71 (Quiroz, 2023). La Enseñanza de las Matemáticas se concibe como el proceso interactivo empleando
72 metodologías que incorporan la IA para desarrollar actividades matemáticas conectando las teorías con
73 la comprensión del mundo real (Davis, 2024), para seleccionar lo relevante de las explicaciones dadas
74 por la IA, realizar diseños esquemas o gráficos al resolver problemas de contextos matemáticos reales
75 o ficticios, según las necesidades y recursos, tanto de las escuelas como de los estudiantes (Quiroz,
76 2023).

77 La teoría del aprendizaje automático es una de las bases de la IA, se trata de la capacidad de las
78 computadoras para aprender desde el análisis de datos para mejorar su rendimiento en actividades
79 específicas como matemáticas (Núñez De Luca et al., 2024), en este aspecto esta teoría es esencial en
80 el desarrollo de algoritmos no solo para resolver problemas complejos de matemáticas sino también
81 les proporciona orientaciones a los estudiantes a fin que comprendan los conceptos subyacentes
82 (Cordero Monzón, 2024). La teoría cognitiva del aprendizaje desarrollado por Bandura, Bruner y otros,
83 inciden en la imitación y en la guía que se brinda a los estudiantes en la resolución de problemas, en
84 este caso la IA también realiza esta función mediante el uso de sistemas inteligentes. Asimismo, el
85 constructivismo propuesto por Vygotsky y Piaget sostiene que el estudiante construye sus aprendizajes

86 interactuando con su medio, en este aspecto la IA con sus plataformas educativas favorece la
87 interactividad al resolver problemas matemáticos según los niveles y ritmos de aprendizaje del
88 estudiante (Esteves Fajardo et al., 2024), haciéndose personalizado y produciéndose la
89 retroalimentación inmediata favoreciendo la auto construcción del conocimiento (Núñez De Luca
90 et al., 2024)

91 Tradicionalmente la educación está centrado en la enseñanza, aunque en las últimas décadas se
92 intenta centrarlo en el aprendizaje (Seivane y Brenlla, 2021), una estrategias de aprendizajes es medir
93 los métodos explícitos, los procedimientos y los comportamientos (G. Wang et al., 2022), para lograr
94 este fin, se está empleando la IA porque permite medir con precisión los desempeños de los
95 estudiantes con la finalidad de mejorar continuamente los aprendizajes (Valdez y Soto, 2022). La IA
51 96 debe colaborar con la implementación de los planes curriculares y nuevas metodologías de enseñanza
97 aprendizaje de las matemáticas (Alissa y Hamadne, 2023). Personalizar la enseñanza aprendizaje es
98 una característica de la IA, también son sistemas que proporcionan características y patrones de
28 99 aprendizaje, así como el desarrollo de actividades colaborativas (Gallent-Torres et al., 2024), la IA se
100 muestra como una herramienta clave para aprovechar en el desarrollo de las habilidades y las
101 capacidades académicas (Barros et al., 2023), en el área de matemáticas con ciertas limitaciones y
102 desafíos para resolver los problemas (Quiroz Rosas, 2023) y (Davis, 2024), pero mejora la retención y
103 acelera la resolución de problemas complejos autónomamente (Núñez De Luca et al., 2024). Sin
104 embargo, si combinamos la inteligencia artificial con las metodologías activas se tiene mejoras
62 105 significativas en el desarrollo de actividades en la educación matemática (Silva et al., 2024), para
71 106 esto es necesario que las instituciones formadoras de docentes de matemáticas incluyan en su planes
107 curriculares la integración de la IA y brindar capacitación a los docentes en actividad a través de
35 108 curso de formación permanente (Saz-Pérez et al., 2024). La IA ha surgido para mejorar el
109 rendimiento académico de los estudiantes y para mejorar la actividad docente en las aulas (Marango
68 110 et al., 2024).

111 1 Metodología

112 Esta investigación es de tipo psicométrico con enfoque cuantitativo, transversal e instrumental
21 113 desarrollándose los procedimientos que conllevan a validar un cuestionario respecto al uso de la
114 Inteligencia Artificial generativa en la enseñanza de las Matemáticas en docentes peruanos del nivel
115 secundario. La estrategia inicial consistió en revisar la literatura relacionados y los estudios

116 precedentes así como en traducir y adaptar el cuestionario “ Nivel de los docentes de ciencia y
3 117 matemáticas en el empleo de Aplicaciones de la Inteligencia Artificial en el Proceso Educativo”
118 elaborado y validado en Jordania por Alissa & Hamadneh (2023), el mismo que es unidimensional y
119 consta de 22 ítems que mide el nivel de los docentes en el empleo de la IA en tres categorías: Bajo.
120 Medio y Alto. Los autores validan dicho cuestionario mediante juicio de expertos acudiendo a 13
121 especialistas en IA y en educación y mediante el método test-retes determinan la confiabilidad de
122 consistencia interna equivalente a 0.91, el estudio también presenta el empleo de los métodos
123 estadísticos descriptivos, el análisis de varianza ANOVA y alfa de Cronbach.

124 En un segundo momento se acude a expertos para para que manifiesten su opiniones y sugerencias.

32 125 Se realiza el procesamiento para obtener el índice de AIKEN respectivo; en seguida se determina la
126 fiabilidad del instrumento aplicando el coeficiente alfa de Cronbach en una prueba piloto. En un
127 tercer momento aplicaremos la versión final del instrumento a la muestra de estudio mediante la
128 herramienta cuestionario de Google y a través de las redes sociales tomando las precauciones del
129 caso. Asimismo, realizaremos una entrevista semi estructurada a algunos docentes y estudiantes.

8 130 Finalmente se realiza el procesamiento de los datos consistente en un análisis factorial exploratorio
8 131 (AFE) con una muestra de 150 docentes y luego de dos meses realizamos el análisis factorial
132 confirmatorio (AFC) con una muestra de 266 docentes de la educación básica, el criterio de inclusión
133 y de exclusión fue siempre que está o no laborando en alguna institución educativa como docente de
134 matemáticas y que tienen algunas experiencias con la IA en la enseñanza. El muestreo fue no
135 probabilístico e intensional.

44 136 En relación con los criterios éticos, los participantes fueron plenamente informados sobre el
137 propósito, los procedimientos y los beneficios de la investigación, asimismo los investigadores se
33 138 comprometen a proteger la identidad y la información personal de los participantes de manera segura
139 sin causar algún tipo de desfavorecimiento.

140 2 Resultados del análisis exploratorio

4 141 2.1 Descripción de la muestra

142 La muestra estuvo conformada por 150 docentes peruanos de matemáticas que laboran en el nivel de
143 educación secundaria, quienes respondieron a los 19 ítems del instrumento. La edad del 66% de los
144 docentes oscila entre 30 y 60 años, el 41% son de género femenino y el 59% son masculinos, el 23%
145 labora en zonas rurales y el 76% en zonas urbanas y se desconoce del resto. Con relación al grado

académico alcanzado, la mayoría reportó contar con un título profesional acompañado del grado de bachiller (44 %; n = 66). Asimismo, el 37.33 % (n = 56) indicó haber culminado estudios de maestría, mientras que el 6 % (n = 9) posee el grado de doctor, el 12.67 % (n = 19) declaró tener un título profesional sin haber obtenido aún el grado de bachiller. Estos datos revelan un perfil académico relativamente alto, con una proporción importante de docentes que ha accedido a estudios de posgrado, lo cual puede tener implicancias relevantes en su práctica pedagógica y su disposición hacia el desarrollo profesional continuo y en el empleo de la IA en sus labres pedagógicas.

2.2 Descripción del Instrumento de Medición

El cuestionario del presente trabajo es uno adaptado del Cuestionario denominado: Nivel de los docentes de ciencia y matemáticas en el empleo de Aplicaciones de la Inteligencia Artificial en el Proceso Educativo” elaborado y validado en Jordania por Alissa & Hamadne (2023); unidimensional que consta de 19 ítems y en su primera parte consta de ítems para obtener información acerca de la población. El propósito del instrumento es medir el uso de la IA en el proceso de la educación matemática que los docentes realizan en el Perú.

2.3 Proceso de Validación

2.3.1 Fiabilidad del instrumento.

Se emplea el coeficiente alfa de Cronbach que se muestran de la siguiente manera:

raw_alpha	std_alpha	G6(smc)	average_r	S/N	ase	mean	sd	median_r
0.96	0.96	0.97	0.57	25	0.0045	3.3	0.79	0.58

Estos os resultados obtenidos fueron altamente satisfactorios: el valor del alfa bruto (raw_alpha) fue de 0.96, lo cual indica un nivel de fiabilidad excelente según los estándares comúnmente aceptados en la literatura psicométrica. De igual modo, el alfa estandarizado (std.alpha) fue también de 0.96, reforzando la evidencia de consistencia interna entre los ítems.

El promedio de correlaciones interítem (average_r = 0.57) refleja una adecuada homogeneidad entre los ítems, sugiriendo que todos ellos contribuyen de manera significativa a la medición del constructo subyacente. La relación señal-ruido (S/N = 25) también fue elevada, lo cual respalda la calidad del instrumento en cuanto a su capacidad para captar información relevante frente a la variabilidad aleatoria.

173 En esta misma línea, el análisis de fiabilidad condicional, si se elimina cada ítem individualmente
174 mostró que la supresión de ningún ítem mejora sustancialmente el índice global. Todos los ítems
175 presentaron correlaciones ítem-total corregidas (r_{drop}) superiores a 0.55, lo que indica que cada uno
176 de ellos mantiene una asociación significativa con el constructo general sin incurrir en redundancia.

69 177 En conjunto, estos resultados permiten concluir que el instrumento posee una consistencia interna
178 robusta y que sus ítems presentan un comportamiento psicométrico adecuado. Por tanto, el
179 cuestionario puede considerarse fiable para fines de medición del Nivel de empleo de Aplicaciones
70 180 con Inteligencia Artificial de los Docentes de Matemáticas en el Proceso Educativo en la Educación
181 Secundaria en el Perú, y es apto para ser utilizado en análisis posteriores tales como estudios
182 correlacionales, modelamientos estructurales o análisis factoriales.

183 2.3.2 Validez de contenido

25 184 Con respecto a la Validez de contenido, se procede mediante el índice V de Aiken, los resultados
185 muestran valores de V de Aiken que oscilan entre 0.515 y 0.660. En términos generales, se observa
186 que varios ítems superan el umbral de 0.60, el cual es comúnmente aceptado como indicador de una
187 validez de contenido aceptable en contextos educativos y sociales. Particularmente, los ítems P1 ($V =$
188 0.629), P2 (0.618), P9 (0.660), y P13 (0.606) presentan una valoración favorable por parte de los
189 jueces, lo cual sugiere que estos ítems son considerados pertinentes y representativos del constructo
190 que se desea medir.

191 No obstante, algunos ítems presentan valores por debajo de 0.55, tales como P14 (0.523), P16
192 (0.515), y P15 (0.551), lo cual podría indicar ciertas debilidades en su formulación o en su alineación
193 con el concepto central del instrumento. Estos ítems deben ser revisados en términos de claridad,
194 relevancia y adecuación contextual, y, de ser necesario, reformulados o sustituidos en futuras
195 versiones del instrumento.

196 En conjunto, los resultados permiten afirmar que el instrumento posee una validez de contenido
197 aceptable en la mayoría de sus componentes, aunque se recomienda una revisión específica de los
198 ítems con menor nivel de acuerdo entre los expertos, a fin de garantizar una mejor representatividad
199 del dominio conceptual asociado al uso docente de aplicaciones basadas en inteligencia artificial.

200 3 Análisis Factorial Exploratorio (AFE)

3.1.1 Análisis de adecuación muestral: Prueba KMO

Con el propósito de determinar la idoneidad de los datos para la aplicación de un análisis factorial exploratorio, se realizó la prueba de adecuación muestral de Kaiser-Meyer-Olkin (KMO). Este índice evalúa la proporción de varianza entre las variables que podría ser común, es decir, que podría atribuirse a un factor latente subyacente.

El valor KMO general obtenido fue de 0.95, lo cual indica un nivel excelente de adecuación muestral, de acuerdo con los criterios establecidos por Kaiser (1974), quien considera valores por encima de 0.90 como "maravillosos" (marvelous), lo que sugiere que los datos son altamente adecuados para proceder con un análisis factorial.

Asimismo, se examinó el índice de adecuación muestral individual (MSA) para cada uno de los ítems del instrumento. Todos los ítems mostraron valores superiores a 0.90, con un rango que va de 0.92 (P2) a 0.97 (P1 y P13), lo cual reafirma que cada ítem presenta una correlación parcial suficientemente baja con el resto, y por tanto contribuye de manera adecuada a la estructura factorial subyacente.

En suma, los resultados del índice KMO respaldan sólidamente la pertinencia de realizar un análisis factorial exploratorio sobre los datos recolectados, ya que tanto el índice global como los individuales reflejan condiciones estadísticas óptimas para la identificación de posibles dimensiones latentes del constructo

3.1.2 Prueba de esfericidad de Bartlett

Complementariamente al índice KMO, se aplicó la prueba de esfericidad de Bartlett con el objetivo de evaluar si las correlaciones entre los ítems del instrumento son suficientemente significativas como para justificar la aplicación de un análisis factorial. Esta prueba contrasta la hipótesis nula de que la matriz de correlaciones es una matriz identidad, lo cual implicaría que las variables no están correlacionadas entre sí y, por tanto, no comparten factores comunes subyacentes.

Los resultados obtenidos fueron altamente significativos: el estadístico de chi-cuadrado fue de $\chi^2(171) = 2401.538$, con un valor $p < 0.001$. Este resultado indica que se rechaza la hipótesis nula con un altísimo nivel de confianza, lo que sugiere que las correlaciones entre las variables son suficientemente fuertes como para proceder con el análisis factorial.

En conjunto con el elevado valor del índice KMO (0.95), estos resultados proporcionan evidencia estadística robusta de que la estructura de correlaciones observada en los datos justifica la

231 exploración de dimensiones latentes mediante técnicas factoriales. De esta manera, tanto la prueba de
232 esfericidad como el índice de adecuación muestral validan la pertinencia metodológica del análisis
233 factorial en el contexto del presente estudio.

58 234 3.1.3 Análisis Factorial Exploratorio

235 Con el propósito de explorar la estructura latente del instrumento diseñado para medir el nivel de
236 empleo de aplicaciones con inteligencia artificial por parte de docentes de matemáticas, se realizó un
237 análisis factorial exploratorio (AFE) utilizando el método de estimación por mínimos residuales
238 (minres). Se extrajeron tres factores con rotación ortogonal Varimax, lo que permitió identificar
239 agrupamientos de ítems con cargas factoriales diferenciadas y una estructura interpretable.

240 Los resultados indicaron cargas factoriales superiores a 0.60 en varios ítems, como el P2 (0.80 en el
241 factor MR2), P11 (0.75 en MR1), y P6 (0.75 en MR3), lo cual sugiere una adecuada asociación de
242 estos ítems con sus respectivos factores. La communalidad (h^2) de los ítems fue generalmente alta, con
243 valores que oscilaron entre 0.38 y 0.79, lo cual evidencia una cantidad considerable de varianza
244 explicada por los factores. El análisis mostró una complejidad promedio de los ítems igual a 2, lo que
245 sugiere que la mayoría de los ítems cargaron de manera significativa en más de un factor.

246 En términos de varianza explicada, los tres factores obtuvieron cargas sustanciales: el primer factor
247 explicó el 35% de la varianza, el segundo un 17%, y el tercero un 13%, acumulando un total del 66%
248 de varianza explicada, lo cual se considera adecuado para este tipo de estudios en ciencias sociales.

249 Los índices de ajuste obtenidos reforzaron la pertinencia del modelo de tres factores. El índice
250 Tucker Lewis (TLI) fue de 0.917, lo cual indica un excelente ajuste del modelo factorial a los datos.

251 El índice de error cuadrático medio de aproximación (RMSEA) fue de 0.084, con un intervalo de
252 confianza al 90% entre 0.069 y 0.099, lo que sugiere un ajuste razonable. El valor del RMSR fue de
253 0.03, también indicativo de un buen ajuste.

57 254 De forma complementaria, se llevó a cabo un análisis factorial con rotación oblicua Promax para
255 examinar la posible correlación entre los factores. Este análisis reveló correlaciones moderadamente
256 altas entre los factores (rango entre 0.67 y 0.73), lo que valida la decisión de aplicar una rotación
257 oblicua como parte del análisis confirmatorio.

258 Los factores identificados presentaron una adecuada adecuación para la puntuación de los factores,
259 con correlaciones entre las puntuaciones obtenidas y los factores latentes superiores a 0.90 en todos
260 los casos, y valores de R cuadrado múltiple de 0.96, 0.88 y 0.88 para los factores MR1, MR2 y MR3

261 respectivamente. Estos resultados indican que el modelo factorial propuesto no solo es
262 estadísticamente sólido, sino que también posee relevancia interpretativa para la medición del
263 constructo evaluado.

3.1.4 Resumen de resultados del Análisis de Componentes Principales (ACP)

Se aplicó un Análisis de Componentes Principales (ACP) sobre los datos estandarizados, y se obtuvo
que: El primer componente principal (PC1) explica aproximadamente el 60% de la varianza total, lo
que indica que contiene la mayor parte de la información de los datos originales. Los dos primeros
componentes (PC1 y PC2) explican en conjunto cerca del 66.7% de la varianza acumulada.

Se necesitan cuatro componentes principales (PC1–PC4) para explicar aproximadamente el 75% de
la varianza total. La varianza acumulada sigue aumentando gradualmente con cada componente
adicional, alcanzando el 100% con los 19 componentes.

Esto sugiere que un número reducido de componentes (por ejemplo, los primeros 4 a 6) puede
capturar una proporción considerable de la variabilidad del conjunto de datos, lo cual es útil para
fines de reducción dimensional o interpretación.

En seguida se muestra de la importancia de las componentes:

Importance of components:

	PC1	PC2	PC3	PC4	PC5	PC6
Standard deviation	3.3757	1.13384	0.89021	0.84932	0.78717	0.73384
Proportion of Variance	0.5998	0.06766	0.04171	0.03797	0.03261	0.02834
Cumulative Proportion	0.5998	0.66742	0.70913	0.74710	0.77971	0.80805
	PC7	PC8	PC9	PC10	PC11	PC12
Standard deviation	0.72103	0.68305	0.62596	0.59876	0.5717	0.56127
Proportion of Variance	0.02736	0.02456	0.02062	0.01887	0.0172	0.01658
Cumulative Proportion	0.83542	0.85997	0.88059	0.89946	0.9167	0.93324
	PC13	PC14	PC15	PC16	PC17	PC18
Standard deviation	0.53509	0.49137	0.44149	0.40356	0.37429	0.35575
Proportion of Variance	0.01507	0.01271	0.01026	0.00857	0.00737	0.00666
Cumulative Proportion	0.94831	0.96102	0.97128	0.97985	0.98723	0.99389
	PC19					
Standard deviation	0.34082					
Proportion of Variance	0.00611					
Cumulative Proportion	1.00000					

Como parte del análisis factorial exploratorio, se evaluó la importancia de los componentes mediante
el cálculo de las desviaciones estándar, la proporción de varianza explicada y la proporción
acumulada de varianza. Los resultados evidencian que el primer componente principal (PC1) posee


280 una desviación estándar de 3.3757, lo que indica un peso sustancial en la estructura factorial. Este
43 281 componente explica por sí solo el 59.98% de la varianza total del conjunto de datos.

282 El segundo componente (PC2) presenta una desviación estándar de 1.1338 y aporta un 6.77%
17 283 adicional de la varianza, acumulando junto con el primero el 66.74% de la varianza total explicada. A
284 partir del tercer componente (PC3), la proporción de varianza explicada por cada componente
285 disminuye notablemente, con valores inferiores al 5%, indicando una menor relevancia individual.

286 En conjunto, los primeros cinco componentes explican aproximadamente el 77.97% de la varianza,
287 mientras que el componente 10 (PC10) marca un punto de saturación en el que ya se ha explicado el
288 89.95% del total. A partir del componente 11 en adelante, los incrementos en la proporción
289 acumulada de varianza son marginales. Finalmente, los 19 componentes explican en su totalidad el
290 100% de la varianza, como es esperado en un análisis de componentes principales sobre un conjunto
291 de 19 variables.

292 Este patrón apoya la retención de un número reducido de componentes, siendo especialmente
293 relevantes los dos primeros, en función de su contribución significativa a la explicación del fenómeno
294 estudiado. Esta interpretación se alinea con los criterios estadísticos de selección de componentes y
295 permite obtener un modelo parsimonioso, robusto y conceptualmente interpretable.

296 Asimismo, presentamos la siguiente Scree Plot que muestra claramente este patrón, ayudando a
297 determinar cuántos componentes retener. Además, las cargas factoriales muestran cómo cada variable
298 original se proyecta sobre los componentes principales, lo que permite interpretar los ejes latentes
299 subyacentes.



300

301 Figura 1. Scree Plot que muestra las cargas factoriales de los componentes.

302 Hay una clara curva (codo) en el gráfico después del primer componente, lo que sugiere que la mayor
303 parte de la varianza se concentra en el primero.

304 3.1.5 Selección del número de componentes factoriales

23 305 La decisión sobre el número óptimo de componentes a retener se fundamenta en el análisis
52 306 combinado del Scree Plot y el criterio de Kaiser. El gráfico de sedimentación (Scree Plot) mostró una
307 clara inflexión ("codo") después del primer componente, lo cual indica que la mayor parte de la
20 308 varianza común es explicada por los primeros dos componentes. Específicamente, el primer
309 componente explicó aproximadamente el 60% de la varianza total, mientras que el segundo
310 componente aportó un 6.8%. A partir del tercer componente, la varianza explicada por cada uno fue
311 considerablemente menor (menos del 5%), lo que sugiere una disminución marcada en el poder
312 explicativo de los factores subsecuentes.

313 Adicionalmente, se aplicó el criterio de Kaiser, el cual recomienda retener únicamente aquellos
314 componentes cuyo eigenvalor sea superior a 1. Este criterio se basó en la idea de que cada
315 componente debe explicar al menos la misma cantidad de varianza que una variable original. En el

316 presente análisis, solo los dos primeros componentes cumplieron con este umbral, lo que respalda
317 aún más la retención de dos factores.

318 Ambos criterios convergieron en la recomendación de retener **dos componentes**, decisión que
319 además encuentra respaldo en la lógica teórica del constructo evaluado y en la economía
320 interpretativa del modelo factorial. Esta solución permite capturar una proporción sustancial de la
321 varianza total con un modelo parsimonioso, facilitando una interpretación conceptual coherente y útil
322 para la investigación empírica.

323 4 Análisis Factorial Confirmatorio (CFA)

324 El modelo CFA fue ajustado con estimación por máxima verosimilitud, sobre una muestra de 266
325 observaciones. Aunque el estadístico Chi-cuadrado ($\chi^2 = 926.594$, $p < .001$) indica un ajuste
326 imperfecto, este resultado debe interpretarse con cautela dada su sensibilidad al tamaño muestral.

14 327 Los índices de ajuste comparativo $CFI = 0.808$ y $TLI = 0.783$ se sitúan por debajo del umbral óptimo
328 de 0.90, sugiriendo un ajuste moderado. El RMSEA fue de 0.148 (IC90%: 0.140–0.158), con un p-
329 valor $< .001$ para $H_0: RMSEA \leq 0.05$, indicando una discrepancia notable entre el modelo y los datos.
330 El SRMR alcanzó 0.394, superando también el valor deseado (< 0.08), lo que refuerza la necesidad
331 de revisar la especificación del modelo.

332 A pesar de estos indicadores de ajuste global, los pesos factoriales estandarizados muestran una
333 fuerte relación entre los ítems y sus factores respectivos. Todas las cargas son significativas ($p <$
334 $.001$), con valores entre 0.612 y 0.972, lo que confirma una buena validez convergente dentro de cada
60 335 dimensión. Además, las varianzas residuales son bajas en la mayoría de los casos, respaldando la
336 consistencia interna de las escalas.

337 En conjunto, aunque el ajuste global del modelo puede ser perfeccionado, la estructura factorial
338 propuesta se sustenta empíricamente, validando su pertinencia teórica y su potencial aplicación en
339 contextos educativos reales. Se sugiere continuar con ajustes parciales o un rediseño de modelo
340 basado en los índices de modificación, a fin de alcanzar una solución más parsimoniosa y con mejor
341 ajuste estadístico.

342 La siguiente tabla, se muestra como evidencia de lo expuesto anteriormente:

Índice	Valor	Criterio de referencia	Evaluación
Chi-cuadrado (χ^2)	926.594	Bajo, pero sensible al N	Alto (ajuste pobre)
Gl (df)	135	—	—
p-valor (χ^2)	0	> 0.05 ideal, pero relativo	No significativo
CFI	0.808	> 0.90 acceptable, > 0.95 ideal	Moderado
TLI	0.783	> 0.90 acceptable	Bajo
RMSEA	0.148	< 0.08 acceptable, < 0.05 ideal	Inaceptable
IC 90% RMSEA	0.140–0.158	—	—
p(RMSEA ≤ 0.05)	0	> 0.05 ideal	No alcanzado
SRMR	0.394	< 0.08	Inaceptable

Nota: La tabla muestra los índices de ajuste del modelo y la buena validez convergente dentro de cada dimensión y las varianzas residuales que son bajas en la mayoría de los casos.


Con la finalidad de ajustar el modelo y alcanzar una solución más adecuada y con mejor ajuste estadístico se evaluó un modelo jerárquico de segundo orden con dos factores de primer orden (Factor1 y Factor2) subordinados a un factor general. El ajuste global del modelo fue aceptable, con índices que respaldan una estructura latente bien definida. Los resultados evidencian que el Factor General explica significativamente la varianza común entre los dos factores de primer orden, lo cual respalda la existencia de una dimensión subyacente global en la medición. En la siguiente tabla se evidencia los resultados.

Categoría	Indicador / Ítem	Valor	Interpretación
Ajuste global del modelo	Chi-cuadrado (χ^2)	447.66 (df = 150, $p < .001$)	Modelo significativamente diferente del nulo
	CFI	0.933	Buen ajuste (> 0.90)
	TLI	0.924	Buen ajuste (> 0.90)
	RMSEA (IC 90%)	0.086 (0.077–0.096)	Marginalmente aceptable (< 0.08 ideal)
	SRMR	0.040	Excelente ajuste (< 0.08)

Categoría	Indicador / Ítem	Valor	Interpretación
Cargas del Factor General	FactorGeneral	0.975	Alta relación
	Factor1		
	FactorGeneral	0.975	Alta relación
	Factor2		
Cargas Factor1 (ítems P1–P10)	Rango de cargas estandarizadas	0.65 – 0.83	Buenas a muy buenas cargas
Cargas Factor2 (ítems P11–P19)	Rango de cargas estandarizadas	0.77 – 0.90	Cargas muy buenas
Varianzas residuales bajas	P11, P12, P14, P18	0.192 – 0.26	Alta precisión de medición
Varianzas residuales más altas	P9, P10	0.548 – 0.574	Error relativamente mayor, aunque aceptable

352 Tabla 2: Muestra en resumen los resultados con ayuda de R mostrando los índices que respaldan una
 353 estructura latente bien definida.

354 Para una mejor visualización se presente la siguiente figura:



355

356 **Figura 2.** Modelo jerárquico de segundo orden obtenido mediante análisis factorial
 357 confirmatorio. El modelo incluye dos factores de primer orden (Factor1 y Factor2) que agrupan
 358 19 ítems observados (P1–P19), y un factor general de segundo orden que explica la covarianza

entre ambos factores. Las flechas indican las cargas factoriales estandarizadas; las flechas curvas representan varianzas y errores. Todas las cargas factoriales son significativas y muestran una adecuada contribución de los ítems a sus factores respectivos, así como una fuerte influencia del factor general sobre los factores de primer orden.

En la figura anterior se presenta un modelo jerárquico de segundo orden en el cual dos factores de primer orden (Factor1 y Factor2) explican la varianza de los ítems observados (P1–P19), mientras que un factor general de segundo orden explica a su vez la covarianza entre estos dos factores primarios. Las cargas factoriales estandarizadas de los ítems sobre sus respectivos factores oscilan entre 0.65 y 0.90, lo que indica una adecuada consistencia interna. Además, el factor general presenta cargas muy altas sobre Factor1 (0.975) y Factor2 (0.975), lo que sugiere la presencia de una dimensión común subyacente que unifica ambas estructuras. Las varianzas residuales son en su mayoría moderadas o bajas, lo que respalda la precisión de las mediciones. Obteniendo el modelo final segundo orden: $\text{FactorGeneral} = \text{Factor1} + \text{Factor2}$.

5 Discusión de los Resultados

Los resultados obtenidos en este estudio proporcionan evidencia significativa de la validación de un instrumento para el caso peruano. Se ha constatado que el cuestionario “Nivel de los docentes de ciencia y matemáticas en el empleo de Aplicaciones de la Inteligencia Artificial en el Proceso Educativo” elaborado y validado en Jordania por Alissa y Hamadneh (2023), ha sido adaptado y es válido para medir el Nivel de los docentes de matemáticas en el empleo de Aplicaciones de la Inteligencia Artificial en el Proceso Educativo en el Perú, obteniéndose un coeficiente de Aiken mayor o igual a 0.515 en casi todos los ítems, y se obtiene un coeficiente de consistencia interna alfa de Cronbach de 0.96; lo que respalda la hipótesis inicial planteada y abre nuevas perspectivas en el ámbito del uso de la IA en el aprendizaje de las matemáticas.

En comparación con el trabajo realizado por Alissa y Hamadneh (2023) que obtienen un coeficiente de consistencia interna alfa de Cronbach de 0.91 en Jordania y no reportan un análisis de validez para los ítems y lo consideran como un instrumento unidimensional; este trabajo ofrece un análisis más profundo para lograr una mejor precisión y validar la estructura del instrumento, realizándose un análisis exploratorio logrando obtener 2 dimensiones para los cuales se muestran sus ítems representantes.

Además, estos resultados destacan porque permiten contar con un instrumento para medir el nivel de los docentes de matemáticas en el empleo de Aplicaciones de la Inteligencia Artificial en el Proceso Educativo en el Perú. Al realizar el análisis exploratorio y el confirmatorio se obtiene el modelo: FactorGeneral (Empleo de la IA) = Factor1 (Empleo propio) + Factor2 (Empleo para enseñar), demostrando que el factor general presenta cargas muy altas sobre Factor1 (0.975) y Factor2 (0.975). Sin embargo, es importante señalar ciertas limitaciones, como, por ejemplo, el tamaño de muestra, solo se cuenta con 266 individuos. Estas limitaciones no disminuyen la relevancia de nuestro estudio, pero sí sugieren la importancia de continuar con investigaciones complementarias que puedan abordar estos aspectos.

6 Conclusión

Este estudio ha logrado adaptar y validar un cuestionario para medir el nivel de los docentes de matemáticas en el empleo de Aplicaciones de la Inteligencia Artificial en el Proceso Educativo para el caso peruano, realizándose y proceso de validación en el cual se obtiene un coeficiente de Aiken moderado o alto (≥ 0.515) en casi todos los ítems y con coeficiente de consistencia interna alfa de Cronbach 0.96.

Asimismo, se ha realizado un análisis exploratorio obteniéndose un índice KMO de 0.95, luego se ha determinado que el instrumento cuenta con 2 dimensiones o factores: (Empleo de la IA) = (Empleo propio) + Factor2 (Empleo para enseñar), contribuyendo así a contar con un instrumento validado para medir el nivel de los docentes de matemáticas en el empleo de Aplicaciones de la Inteligencia Artificial en el Proceso Educativo en el Perú, que nos permita realizar más investigaciones respecto a las bondades de la IA en el campo educativo y emplear con solidez sus atributos en la enseñanza de las matemáticas y de otras disciplinas.

7 Referencias

- Alissa, R. A. S., & Hamadneh, M. A. (2023). The Level of Science and Mathematics Teachers' Employment of Artificial Intelligence Applications in the Educational Process. *International Journal of Education in Mathematics, Science and Technology*, 11(6), 1597-1608.
<https://doi.org/10.46328/ijemst.3806>
- Andrade-Girón, D., Marín-Rodríguez, W., Sandivar-Rosas, J., Carreño-Cisneros, E., Susanibar-Ramirez, E., Zuñiga-Rojas, M., Angeles-Morales, J., & Villarreal-Torres, H. (2024).

- 417 Generative artificial intelligence in higher education learning: A review based on academic
418 databases. *Iberoamerican Journal of Science Measurement and Communication*, 4(1), 1-16.
419 <https://doi.org/10.47909/ijsmc.101>
- 420 Barros, A., Prasad, A., & Śliwa, M. (2023). Generative artificial intelligence and academia:
421 Implication for research, teaching and service. *Management Learning*, 54(5), 597-604.
422 <https://doi.org/10.1177/13505076231201445>
- 423 Bejarano Cordoba, A. S., & Guerrero Godoy, R. S. (2021). Uso de herramientas tecnológicas para la
424 resolución de problemas en el área de las matemáticas. *Revista EDUCARE - UPEL-IPB -*
425 *Segunda Nueva Etapa 2.0*, 25(3), 7-27. <https://doi.org/10.46498/reduipb.v25i3.1522>
- 426 Cordero Monzón, M. Á. (2024). Inteligencia Artificial en el aula: Oportunidades y desafíos para la
427 didáctica de la matemática y física universitaria. *Revista Internacional de Pedagogía e*
428 *Innovación Educativa*, 4(1), 193-207. <https://doi.org/10.51660/ripie.v4i1.154>
- 429 Davis, E. (2024). MATHEMATICS, WORD PROBLEMS, COMMON SENSE, AND ARTIFICIAL
430 INTELLIGENCE. *Bulletin of the American Mathematical Society*, 61(2), 287-303.
431 <https://doi.org/doi.org/10.1090/bull/1828>
- 432 Esteves Fajardo, Z. I., Cevallos Gamboa, M. A., Herrera Valdivieso, M. V., & Muñoz Murillo, J. P.
433 (2024). Cómo impacta la inteligencia artificial en la educación. *RECIAMUC*, 8(1), 62-70.
434 [https://doi.org/10.26820/reciamuc/8.\(1\).ene.2024.62-70](https://doi.org/10.26820/reciamuc/8.(1).ene.2024.62-70)
- 435 Gallent-Torres, C., Arenas Romero, B., Vallespir Adillón, M., & Foltýnek, T. (2024). Inteligencia
436 Artificial en educación: Entre riesgos y potencialidades. *Praxis Educativa*, 19(2024), 1-29.
437 <https://doi.org/10.5212/PraxEduc.v.19.23760.083>
- 438 Gálvez Marquina, M. C., Pinto-Villar, Y. M., Mendoza Aranzamendi, J. A., & Anyosa Gutiérrez., B.
439 J. (2024). Adaptación y validación de un instrumento para medir las actitudes de los
440 universitarios hacia la inteligencia artificial. *Revista de Comunicación*, 23(2), 125-142.
441 <https://doi.org/10.26441/RC23.2-2024-3493>
- 442 Grassini, S. (2023). Development and validation of the AI attitude scale (AIAS-4): A brief measure
443 of general attitude toward artificial intelligence. *Frontiers in Psychology*, 14, 1191628.
444 <https://doi.org/10.3389/fpsyg.2023.1191628>
- 445 Marango, A., Yilmaz, F. G. K., Ceylan, M., & Soomro, K. A. (2024). *Development and Validation of*
446 *Generative Artificial Intelligence Attitude Scale for Students*. 16.

- 447 Montoya Asprilla, J. Y. (2024). Percepciones y Actitudes hacia la Integración de la Inteligencia
448 Artificial en la Enseñanza de las Ciencias Sociales en la Universidad Tecnológica del Chocó.
449 *Technology Rain Journal*, 3(2). <https://doi.org/10.55204/trj.v3i2.e41>
- 450 Nemt-allah, M., Khalifa, W., Badawy, M., Elbably, Y., & Ibrahim, A. (2024). Validating the
451 ChatGPT Usage Scale: Psychometric properties and factor structures among postgraduate
452 students. *BMC Psychology*, 12(1). Scopus. <https://doi.org/10.1186/s40359-024-01983-4>
- 453 Ng, D. T. K., Wu, W., Leung, J. K. L., Chiu, T. K. F., & Chu, S. K. W. (2024). Design and validation
454 of the AI literacy questionnaire: The affective, behavioural, cognitive and ethical approach.
455 *British Journal of Educational Technology*, 55(3), 1082-1104.
456 <https://doi.org/10.1111/bjet.13411>
- 457 Núñez De Luca, J. M., Avila Valdez, J. L., Ávila Guamán, L. O., & Cuecuecha Sánchez, L. Á.
458 (2024). Empleo de la inteligencia artificial para resolver problemas matemáticos en el ámbito
459 de la educación superior. *Reincisol.*, 3(6), 3415-3433.
460 [https://doi.org/10.59282/reincisol.V3\(6\)3415-3433](https://doi.org/10.59282/reincisol.V3(6)3415-3433)
- 461 Opesemowo, O. A. G., & Adewuyi, H. O. (2024). A systematic review of artificial intelligence in
462 mathematics education: The emergence of 4IR. *Eurasia Journal of Mathematics, Science and*
463 *Technology Education*, 20(7), em2478. <https://doi.org/10.29333/ejmste/14762>
- 464 Panqueban, D., & Huincahue, J. (2024). Inteligencia Artificial en educación matemática: Una
465 revisión sistemática. *Uniciencia*, 38(1), 1-17. <https://doi.org/10.15359/ru.38-1.20>
- 466 Quiroz Rosas, V. (2023). Aplicaciones de Inteligencia Artificial Aliadas en la Enseñanza de las
467 Matemáticas. *Ciencia Latina Revista Científica Multidisciplinar*, 7(4), 10547-10560.
468 https://doi.org/10.37811/cl_rcm.v7i4.8070
- 469 Ríos Hernández, I. N., Mateus, J.-C., Rivera-Rogel, D., & Ávila Meléndez, L. R. (2024).
470 Percepciones de estudiantes latinoamericanos sobre el uso de la inteligencia artificial en la
471 educación superior. *AustralComunicación.*, 13(1), 2-25.
- 472 Rodríguez-Gutiérrez, S. A., Vidrio-Barón, S. B., & Vásquez Sánchez, J. R. (2024). Modelo para
473 evaluar la aceptación de la herramienta ChatGPT en la generación Z. *Vinculatégica EFAN*,
474 10(5), 138-154. <https://doi.org/10.29105/vtga10.5-1069>
- 475 Saz-Pérez, F., Pizá-Mir, B., & Lizana Carrió, A. (2024). Validación y estructura factorial de un
476 cuestionario TPACK en el contexto de Inteligencia Artificial Generativa (IAG). *Hachetetepé*.

- 477 *Revista científica de educación y comunicación*, 28.
478 <https://doi.org/10.25267/Hachetetepe.2024.i28.1101>
- 479 Seivane, M., & Brenlla, M. (2021). Evaluación de la Calidad Docente Universitaria desde la
480 Perspectiva de los Estudiantes. *Revista Iberoamericana de Evaluación Educativa*, 14(1), 35-
481 46. <https://doi.org/10.15366/riee2021.14.1.002>
- 482 Sevilla, T. C. S., & Barrios, M. B. (2024). Actitudes de los estudiantes de educación básica hacia la
483 inteligencia artificial: Una adaptación. *REVISTA INVECOM*, 4(2).
- 484 Silva, M., Correa, R., & Mc-Guire, P. (2024). Metodologías Activas con Inteligencia Artificial y su
485 relación con la enseñanza de la matemática en la educación superior en Chile. Estado del arte.
486 *Revista Iberoamericana de Tecnología en Educación y Educación en Tecnología*, 37, e2.
487 <https://doi.org/10.24215/18509959.37.e2>
- 488 Valdez, A., & Soto, G. A. (2022). 1. EVALUACIÓN DE LOS APRENDIZAJES CON
489 INTELIGENCIA ARTIFICIAL EN EDUCACIÓN MEDIA SUPERIOR. *Revista de*
490 *Investigación Transdisciplinar en Educación, Empresa y Sociedad*.
- 491 Vankúš, P. (2024). *Generative Artificial Intelligence on Mobile Devices in the University*
492 *Preparation of Future Teachers of Mathematics*. 18(18), 19-33.
493 <https://doi.org/10.3991/ijim.v18i18.51221>
- 494 Wang, C., Li, T., Lu, Z., Wang, Z., Alballa, T., Alhabeeb, S. A., Albely, M. S., & Khalifa, H. A. E.-
495 W. (2025). Application of artificial intelligence for feature engineering in education sector
496 and learning science. *Alexandria Engineering Journal*, 110, 108-115.
497 <https://doi.org/10.1016/j.aej.2024.09.100>
- 498 Wang, G., Chen, X., Zhang, D., Kang, Y., Wang, F., & Su, M. (2022). Development and Application
499 of an Intelligent Assessment System for Mathematics Learning Strategy among High School
500 Students—Take Jianzha County as an Example. *Sustainability*, 14(19), 12265.
501 <https://doi.org/10.3390/su141912265>