

Inteligencia artificial y rendimiento académico en estadística descriptiva de estudiantes de ingeniería de la UPEC

Artificial Intelligence and Academic Performance in Descriptive Statistics among UPEC Engineering Students

<https://doi.org/10.58995/redlic.rmic.v5.n1.a252>



Walter Joffred Jácome Vélez  ¹, Juan Carlos López Ruano ²

¹ **Universidad Politécnica Estatal del Carchi**

walter.jacome@upec.edu.ec

Tulcán-Ecuador

² **Universidad Politécnica Estatal del Carchi**

carlos.lopez@upec.edu.ec

Tulcán-Ecuador

¿Como citar?

Jácome Vélez , W. J. ., & López Ruano , J. C. . (2027). Inteligencia artificial y rendimiento académico en estadística descriptiva de estudiantes de ingeniería de la UPEC. *Revista Multidisciplinaria Investigación Contemporánea*, 5(1), 32-52. <https://doi.org/10.58995/redlic.rmic.v5.n1.a252>

Recibido: 16-05-2026

Aceptado: 03-09-2026

Publicado: 01-01-2027

Nota del editor

REDLIC se mantiene neutral con respecto a reclamos jurisdiccionales en mensajes publicados y afiliaciones institucionales.

Editorial


Red Editorial Latinoamericana de Investigación Contemporánea (REDLIC)
www.editorialredlic.com

Fuentes de financiamiento

La investigación fue realizada con recursos propios

Conflictos de interés

No presentan conflicto de intereses.



Este es un artículo de acceso abierto, bajo licencia [Creative Commons \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/) de Atribución 4.0 Internacional

Resumen

La incorporación de herramientas de Inteligencia Artificial (IA) en la educación superior ha transformado el aprendizaje. Esta investigación tuvo como objetivo analizar la influencia del uso de IA en el rendimiento académico de estudiantes de Estadística Descriptiva de la UPEC. Se empleó un enfoque cuantitativo y correlacional, aplicando una encuesta a 155 estudiantes. Para validar la estructura del estudio, se utilizaron el Análisis Factorial Exploratorio (AFE) y Confirmatorio (AFC). Los resultados del AFE y AFC confirmaron una estructura bidimensional compuesta por "Uso y percepción académica de la IA" y "Competencia percibida en su uso". Los hallazgos sugieren que la integración de herramientas de IA contribuye positivamente al proceso de aprendizaje de contenidos estadísticos. Se concluye que la IA es un recurso educativo valioso que fortalece el desempeño académico, siempre que su utilización se desarrolle bajo principios de equidad, transparencia y responsabilidad para apoyar las decisiones pedagógicas basadas en evidencia.

Palabras clave: inteligencia artificial; rendimiento académico; estadística; análisis factorial exploratorio; análisis factorial comprobatorio.

Abstract

The incorporation of Artificial Intelligence (AI) tools into higher education has transformed learning. The objective of this study was to analyze the influence of AI use on the academic performance of students in the Descriptive Statistics course at UPEC. A quantitative and correlational approach was employed, using a survey administered to 155 students. To validate the study's structure, Exploratory Factor Analysis (EFA) and Confirmatory Factor Analysis (CFA) were used. The results of the EFA and CFA confirmed a two-dimensional structure comprising "Use and Academic Perception of AI" and "Perceived Competence in Its Use." The findings suggest that the integration of AI tools contributes positively to the learning process of statistical content. It is concluded that AI is a valuable educational resource that enhances academic performance, provided that its use is guided by principles of equity, transparency, and accountability to support evidence-based pedagogical decisions.

Keywords: artificial intelligence; academic performance; statistics; exploratory factor analysis; confirmatory factor analysis.

1. Introducción

En la Universidad Politécnica Estatal del Carchi (UPEC), el uso de herramientas de inteligencia artificial por parte de los estudiantes ha experimentado un crecimiento considerable; existe escasa evidencia científica que permita determinar cómo estas

tecnologías influyen específicamente en el rendimiento académico de los estudiantes en asignaturas relacionadas con la estadística descriptiva. Esta situación justifica la realización de la presente investigación, orientada a analizar la influencia del uso de

herramientas de inteligencia artificial en el rendimiento académico de los estudiantes de ingeniería de la UPEC, contribuyendo así a la generación de conocimiento que permita fortalecer los procesos educativos y promover una integración efectiva de estas tecnologías en la educación superior.

El desarrollo de la inteligencia artificial generativa, como ChatGPT, ha transformado profundamente una amplia gama de actividades humanas al permitir la producción automatizada de textos, análisis y respuestas en tiempo real. (Acero & Alba, 2025).

La inteligencia artificial (IA) está transformando rápidamente la sociedad y los sectores, lo que plantea tanto oportunidades como retos éticos. La IA permite a las máquinas realizar tareas que tradicionalmente llevaban a cabo los seres humanos, como el procesamiento del lenguaje natural, el reconocimiento de patrones, la toma de decisiones y la resolución de problemas (Leddy & McCreanor, 2024).

En el ámbito de la tecnología educativa, la inteligencia artificial aplicada a la educación (AIED) es un campo emergente que se prevé que tenga un profundo impacto en el proceso de enseñanza y aprendizaje (Tan, 2023).

El rendimiento académico se define de varias formas; de acuerdo con ciertos autores, se considera que es un valor que indica el nivel de aprendizaje de los estudiantes y que depende de varios factores. El rendimiento académico es una parte fundamental en el proceso de enseñanza y aprendizaje, porque nos permite identificar si el estudiante cumple con los estándares de aprendizaje que dispone el currículo de educación para ser promovido al siguiente nivel. Dentro de la evaluación del rendimiento académico, se puede aplicar la inte-

ligencia artificial para predecir el abandono académico en la educación superior. Destaca que el abandono académico no solo afecta a las personas, sino también a los recursos institucionales y a la sociedad en general (Tan, 2023).

En el estudio del rendimiento académico se evidencia una premisa ampliamente aceptada, sostiene que los estudios universitarios representan uno de los principales factores de ascenso social y cultural en la población de un país. Esta noción ayuda a explicar los altos índices de matrícula universitaria en América Latina (Comolli et al., 2026).

La inteligencia artificial ha llegado al mundo de la universidad, tanto en el plano de los alumnos que acceden a los estudios superiores como en el profesorado que se encuentra en su doble vertiente como docentes e investigadores con esta realidad tecnológica que no hace sino crecer (Garza, 2024).

2. Materiales y métodos

La investigación se centra en la Universidad Politécnica Estatal del Carchi, universidad pública ubicada en el cantón Tulcán, de la provincia del Carchi; la misma es una institución de educación superior pública y acreditada, que satisface las demandas sociales a través de la formación de grado y posgrado, la investigación, la vinculación con la sociedad y la gestión, generando conocimiento que contribuye al desarrollo económico, social, científico-tecnológico, cultural y ambiental de la región.

El objetivo de este trabajo es determinar cuáles son los factores de índole académico, familiar, personal, y social que influyen en el rendimiento académico en un grupo de estudiantes de la materia de Estadística

ca descriptiva de la UPEC, para lo cual se aplicaron técnicas de análisis multivariado.

El presente estudio se enmarca en el enfoque cualitativo, ya que se fundamenta en la recolección y análisis de datos de una encuesta realizada a los estudiantes de Estadística Descriptiva de la UPEC, además del enfoque cuantitativo, al aplicar matrices de correlación y el análisis factorial de reducción de dimensiones, como lo son el análisis factorial exploratorio (AFE), y el análisis factorial confirmatorio (AFC). Con el objetivo de examinar relaciones estadísticas entre variables y establecer conclusiones objetivas a partir de la aplicación de métodos multivariantes. Las preguntas realizadas en el cuestionario presentan una buena orientación para una investigación correlacional, o explicativa sobre el uso de herramientas de inteligencia artificial y el rendimiento académico en los estudiantes, todo esto basado en la verificación de los supuestos previos que los datos deben cumplir, para que los resultados sean válidos. El alcance de la investigación correlacional y explicativa: en primera instancia, se busca establecer la existencia y la intensidad de la relación entre el uso de herramientas de IA, y el rendimiento académico; posteriormente, se pretende explicar cómo y en qué medida el uso de estas tecnologías impacta en el aprendizaje de contenidos estadísticos. Para esto, se aplica el análisis multivariante, una técnica estadística avanzada que permite explorar patrones ocultos entre múltiples variables simultáneamente, identificar factores latentes, y comprender estructuras subyacentes que afectan al desempeño estudiantil.

El tipo de estudio es no experimental, dado que no se manipulan deliberadamente las variables independientes, sino que

se observan en su contexto natural, el diseño es transversal, ya que la información fue recolectada en un solo momento del tiempo, permitiendo una “fotografía” del fenómeno investigado durante el período académico 2025A.

Se usa un programa de última generación para realizar análisis de datos, lo cual lo hace versátil, con un lenguaje de programación en un dialecto denominado S (Jiménez, 2019).

Las técnicas cuantitativas incluyen métodos o herramientas que se centran en la medición objetiva y el análisis de números, para sacar conclusiones sobre problemas dados. Es un método o técnica científica utilizado por el mundo empresarial y académico para la resolución de problemas y la toma de decisiones. Así mismo, el estudio de las técnicas cuantitativas ha sido un concepto relativamente nuevo, que tiene grandes aplicaciones en la academia y otros campos de la vida (K. M. A. Sánchez & Sandoval, 2024).

El AFE, es el nombre genérico con que se designa a un conjunto de métodos estadísticos multivariados de independencia cuyo propósito principal es identificar una estructura de factores subyacentes a un conjunto amplio de datos (Pérez & Medrano, 2010).

Para el análisis estadístico de los datos, se llevó a cabo un análisis factorial confirmatorio, con la finalidad de obtener evidencias de la validez de constructo de la escala. Se eligió usar el método de estimación de máxima verosimilitud robusta por ajustarse correctamente a datos con faltas de normalidad estadística o de muestras medianas o pequeñas (Barrientos Durán et al., 2024).

3. Resultados

Para realizar los criterios de métodos multivariados, se realizó una encuesta digital, a los estudiantes que cursaron la materia de Estadística descriptiva, en el período académico 2025A. Para desarrollar el análisis de esta, y poder concluir el impacto que tiene el uso de la inteligencia artificial, en materias de uso de datos, como lo es la estadística. Es una encuesta estructurada tipo cuestionario digital, mediante el Google Forms, y exportada desde el Excel. Este tipo de encuesta generalmente es utilizada para investigaciones, porque recoge la información estandarizada de muchos participantes mediante preguntas cerradas y de escalas.

La encuesta recoge datos cuantitativos, datos numéricos y categóricos que se pueden analizar estadísticamente, además de ser de forma transversal, ya que se obtiene en un solo momento del tiempo, sin seguimiento longitudinal.

Nos centraremos también en un análisis correlacional, buscaremos relacionar las variables, además de que, en su mayoría, las respuestas son categóricas se usa como instrumento las escalas Likert. Se escogió de la encuesta la parte que conlleva el valor de interés del trabajo: 15 preguntas de escalas Likert, para aplicar las herramientas estadísticas como la reducción de dimensiones y poder interpretar su incidencia.

Después de analizar la base de datos obtenida, que es de tipo ordinal con escala, aplicada generalmente en las encuestas realizadas. Realizaremos un análisis factorial exploratorio y confirmatorio; se realiza una visualización de los datos por medio del programa R-studio.

3.1. Visualización de los datos

Se realiza un summary, a todos los datos para verificar que no haya ningún valor atípico, o algún valor faltante, identificando o anunciando que existe algún valor dentro de las columnas de la encuesta que estén faltando.

p1	p2	p3	p4	p5	p6
Min. :1.000	Min. :1.000	Min. :1.0	Min. :1.000	Min. :1.000	Min. :1.000
1st Qu.:1.000	1st Qu.:2.000	1st Qu.:1.0	1st Qu.:1.000	1st Qu.:1.000	1st Qu.:1.500
Median :2.000	Median :2.000	Median :4.0	Median :2.000	Median :3.000	Median :3.000
Mean :2.619	Mean :1.903	Mean :3.2	Mean :2.419	Mean :2.529	Mean :2.806
3rd Qu.:4.000	3rd Qu.:2.000	3rd Qu.:5.0	3rd Qu.:4.000	3rd Qu.:4.000	3rd Qu.:4.000
Max. :5.000	Max. :3.000	Max. :5.0	Max. :5.000	Max. :5.000	Max. :5.000
p7	p8	p9	p10	p11	p12
Min. :1.000	Min. :1.000	Min. :1.000	Min. :1.000	Min. :1.000	Min. :1.000
1st Qu.:1.000	1st Qu.:1.000	1st Qu.:1.000	1st Qu.:1.000	1st Qu.:1.000	1st Qu.:1.000
Median :3.000	Median :4.000	Median :3.000	Median :3.000	Median :4.000	Median :2.000
Mean :2.703	Mean :3.026	Mean :2.961	Mean :2.781	Mean :2.981	Mean :2.897
3rd Qu.:4.000	3rd Qu.:5.000	3rd Qu.:5.000	3rd Qu.:4.000	3rd Qu.:5.000	3rd Qu.:5.000
Max. :5.000	Max. :5.000	Max. :5.000	Max. :5.000	Max. :5.000	Max. :5.000
p13	p14	p15			
Min. :1.000	Min. :1.000	Min. :1.000			
1st Qu.:1.000	1st Qu.:2.000	1st Qu.:1.000			
Median :1.000	Median :3.000	Median :2.000			
Mean :1.335	Mean :3.213	Mean :2.742			
3rd Qu.:2.000	3rd Qu.:5.000	3rd Qu.:5.000			
Max. :3.000	Max. :5.000	Max. :5.000			

Figura 1. Refleja que, de las 15 preguntas o variables, no hay inconsistencias. Fuente: Walter Jácome Vélez (2026).

Ahora procedemos a obtener las desviaciones estándar de cada una de las variables; en caso de que alguna, resulte ser igual entre variables, se procede a eliminar una de las preguntas.

Tabla 1: SD de cada variable

Variable	SD	Variable	SD	Variable	SD
P1	1.6525108	P6	1.1903114	P11	1.7487323
P2	0.4526142	P7	1.4287139	P12	1.7734484
P3	1.7706115	P8	1.7579075	P13	0.5256711
P4	1.3429516	P9	1.8265142	P14	1.5246336
P5	1.4293295	P10	1.6642574	P15	1.7722196

Nota. Fuente: Walter Jácome Vélez. (2026)

Podemos respaldar esto con un gráfico, bajo la condición del comando boxplot.




Figura 2. Gráfico de las variables en conjunto. Fuente: Walter Jácome Vélez (2026).

3.2. Tratamiento de los datos.

Se tienen varias variables; aplicaremos una técnica, la cual es la distancia de Mahalanobis, donde extraemos la parte numérica de nuestros datos. La distancia de Mahalanobis son puntajes muy parecidos a las distancias euclidianas respecto a un centroide.

Se calcula una distancia multivariante para cada variable de la muestra; cada número representa ¿qué tan lejos está cada observación?, respecto al centro multivariante de todas las variables analizadas.

[1]	17.058491	17.080263	22.031795	10.126437	13.922617	8.829909	17.970462	12.969533	18.667444	20.662695
[11]	10.530474	21.592762	9.757001	17.566444	12.476077	24.375185	18.304015	15.674172	16.759235	13.239120
[21]	11.691481	19.977901	19.201241	26.521055	21.437415	15.790411	12.579283	13.811824	16.587208	9.604648
[31]	22.769872	20.793791	14.507410	14.892176	8.121056	20.439552	15.710457	9.682063	6.823689	12.613835
[41]	12.071644	11.338488	14.250358	11.029546	11.202761	15.850233	11.833618	12.755001	21.812266	17.341997
[51]	17.562048	3.794603	17.010620	3.620494	16.667902	6.077223	20.440522	15.831055	20.341951	24.893347
[61]	10.337191	11.774046	19.572909	16.578850	18.465758	13.260530	22.954915	22.888174	25.881042	28.120504
[71]	10.167896	11.622598	15.728560	11.926658	14.300409	24.294544	25.714745	7.636056	15.745471	21.885183
[81]	15.330547	18.553785	11.103995	13.781362	14.380196	22.841264	11.362856	16.025514	12.544976	22.133677
[91]	20.797485	25.675357	16.325326	17.028670	7.697834	12.566770	8.503664	17.334159	8.466551	15.470877
[101]	25.174128	22.588787	8.545260	6.573155	16.342422	12.106980	13.575609	12.273573	13.470436	20.480723
[111]	14.889517	17.155299	14.148052	4.477493	14.240814	9.125732	17.675592	10.101313	18.914832	13.059031
[121]	22.077422	12.483563	6.639750	15.146580	20.727394	14.819207	7.827995	8.337935	15.560741	18.757597
[131]	11.118132	5.675553	6.370778	22.982455	19.968111	11.344397	7.381999	9.906511	4.698143	17.845796
[141]	11.586650	12.166064	7.530174	23.600645	20.870885	13.498701	8.167342	11.907331	8.473929	5.430588
[151]	14.372848	14.562127	7.828290	14.030838	16.228202					

Figura 3. Captura de las distancias de Mahalanobis. Fuente: Walter Jácome Vélez (2026)

El punto de corte es de 37.6973; esto significa que toda observación con la distancia de Mahalanobis mayor a 37.6973 será considerada un valor atípico multivariado.

Matemáticamente hablando:

$$D^2 > 37.6973 \quad (1)$$

El número mayor de los datos de las distancias calculadas es de 28.120504, lo cual podemos dar como resultado que no existe valor atípico multivariado en los datos, que las 155 observaciones han sido aceptadas.

3.3. Supuestos estadísticos de la muestra

La verificación de los supuestos estadísticos adicionales es para estar seguros de que las técnicas multivariantes que se irán a realizar no tengan ningún problema al aplicarlas e interpretarlas.

3.3.1. Aditividad

Este supuesto estadístico, es para evidenciar que no existen correlaciones perfectas, o bivariadas perfectas, esto es, que una columna no tenga los mismos valores que otras columnas de los datos, y eso capaz signifique que se esté preguntando lo mismo 2 veces.




Figura 3. Matriz de correlación entre las variables. Fuente: Walter Jácome Vélez (2026).

En caso de coincidir con el valor de 1 en la matriz entre algunas de las preguntas, se toma la decisión de eliminar una de las dos.

3.3.2. Normalidad

Se realiza el supuesto de normalidad, o de falsa regresión; se utiliza la distribución

normal para una sola variable, la Ji-cuadrado, para múltiples variables; cabe señalar que, de ser multimodal, no se aceptaría, y se estandariza la Ji-cuadrado para realizar el histograma.




Figura 4. Histograma estandarizado de falsa regresión. Fuente: Walter Jácome Vélez (2026).

3.3.3. Linealidad

Es un gráfico donde podemos considerar, en el intervalo de -2 a 2, si cumple con el supuesto de linealidad; de no cumplirse,

se rechaza la muestra con una muestra paramétrica y tendrá que ser considerada como una muestra no paramétrica.




Figura 5. Gráfico QQ-plot de linealidad. Fuente: Walter Jácome Vélez (2026).

3.3.4. Homogeneidad y Homocedasticidad

Al analizar la dispersión de los datos, debemos observar que no haya divergencia; dentro de la homogeneidad y homocedasticidad, la dispersión debe estar bien

distribuida y como una nube ovalada; podremos verificar que este supuesto sí se cumple.




Figura 6. Gráfico del supuesto de Homogeneidad y homocedasticidad. Fuente: Walter Jácome Vélez (2026).

3.3.5. Suficiencia de correlación

Se procede a aplicar la suficiencia de correlación de Bartlett; es uno de los supuestos estadísticos dentro de la validación de los datos obtenidos. Consiste en comparar cada una de las preguntas, verificando correlaciones significativamente diferentes. La decisión estadística sería:

$$p < 0.05 \quad (2)$$

Basados en las hipótesis:

H_0 : la matriz de correlaciones es una matriz identidad

H_1 : las variables si están correlacionadas significativamente.

El valor del p-valor es de: 5.770485e-50, lo cual es un valor extremadamente pequeño; por tanto, rechazamos la hipótesis nula. Esto significa que sí existe una correlación significativa entre las variables de la encuesta. Por lo que sí procede a un análisis factorial.

3.3.6. Suficiencia de muestreo (KAISER-MEYER-OLKIN)

Este supuesto de suficiencia nos permite asegurar, que la muestra sea lo suficientemente grande, ya que se va a trabajar sobre el modelo de correlación.

Tabla 2: Estadísticos de suficiencia de muestreo KMO.

Preguntas	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	P11	P12	P13	P14	P15
Estadísticos	0.79	0.55	0.69	0.75	0.69	0.64	0.79	0.77	0.77	0.81	0.83	0.79	0.62	0.76	0.67

Nota. Fuente: Walter Jácome Vélez. (2026)

El análisis presenta una estructura estadística aceptable y puede continuar hacia análisis factorial exploratorio. No obstante, los ítems p2 y p13 muestran debilidad psicométrica. Normalmente, las encuestas suelen tener como debilidad algunas preguntas, de ahí la importancia del juicio de expertos en la formulación de los cuestionarios. Los resultados después de estos supuestos son muy favorables, para continuar con el análisis factorial exploratorio.

3.4. Análisis factorial exploratorio

Se realiza el análisis factorial exploratorio, lo cual trata de obtener una estructura simple, o una estructura reducida en unos pocos factores para todos esos conjuntos de preguntas, cuáles se pueden asociar y cuáles no.

3.4.1. Criterio de esfericidad

Se realiza el análisis factorial, comenzando por el criterio de esfericidad mediante un Scree Plot, o gráfico de sedimentación del análisis factorial exploratorio. Es el inicio para evidenciar cuántos factores o componentes deben conservarse en el modelo.




Figura 7. Criterio de Esfericidad para el AFE. Fuente: Walter Jácome Vélez (2026).

Se busca un punto de inflexión, o un codo propiamente dicho, un lugar donde cambia la curvatura, para realizar el siguiente paso del AFE. Es una forma gráfica de la interpretación de estudio, además de los criterios de la varianza acumulada, el criterio de Kaiser.

El gráfico de sedimentación muestra un descenso pronunciado en los primeros

componentes y una estabilización posterior de la curva, sugiriendo la presencia de entre dos y tres factores principales.

3.4.2. Análisis paralelo

Este gráfico es considerado uno de los métodos más robustos y recomendados para decidir cuántos factores deben retenerse en un análisis factorial exploratorio.




Figura 8. Análisis paralelo en el estudio del AFE. Fuente: Walter Jácome Vélez (2026).

Para poder interpretar el gráfico, buscamos dónde se intersecan, dónde se acumula la mayor cantidad de varianzas. Además, muestra que únicamente dos factores presentaron autovalores superiores a los obtenidos mediante datos aleatorios simulados. Aunque el tercer factor mostró una contribución marginal, la solución factorial de dos dimensiones resultó la más consistente e interpretable.

3.4.3. Criterio de Kaiser

Este criterio da a conocer de manera analítica con cuántos factores es necesario trabajar; según el criterio de Kaiser, se debe trabajar con 2 factores.

3.4.4. Ejecución de la prueba

Es propiamente el resultado del análisis factorial exploratorio, (AFE), se realiza para encontrar cuál es la estructura factorial que podemos utilizar para esta encuesta.

```
Factor Analysis using method = ml
Call: fa(r = SinAtipicos, nfactors = 2, rotate = "oblimin", fm = "ml")
Standardized loadings (pattern matrix) based upon correlation matrix

    ML1    ML2    h2    u2 com
p1  0.32  0.15 0.1523 0.85 1.4
p2 -0.02 -0.08 0.0072 0.99 1.1
p3  0.38  0.02 0.1463 0.85 1.0
p4  0.03  0.54 0.2986 0.70 1.0
p5  0.05  0.60 0.3802 0.62 1.0
p6 -0.10  0.66 0.4072 0.59 1.0
p7  0.23  0.45 0.3129 0.69 1.5
p8  0.81  0.01 0.6581 0.34 1.0
p9  0.73 -0.01 0.5341 0.47 1.0
p10 0.49  0.10 0.2794 0.72 1.1
p11 0.60 -0.02 0.3512 0.65 1.0
p12 0.41  0.16 0.2327 0.77 1.3
p13 -0.02  0.04 0.0019 1.00 1.4
p14 0.50 -0.14 0.2270 0.77 1.2
p15 0.41 -0.05 0.1575 0.84 1.0

    SS loadings    ML1 ML2
Proportion Var    2.72 1.42
Cumulative Var    0.18 0.09
Proportion Explained 0.18 0.28
Cumulative Proportion 0.66 1.00

With factor correlations of
    ML1 ML2
ML1 1.00 0.29
ML2 0.29 1.00
```

Figura 9. Análisis factorial exploratorio. Fuente: Walter Jácome Vélez (2026).

Se realiza el análisis factorial exploratorio mediante el método de rotación matricial, con el tipo de ajustes de máxima verosimilitud.

Se procede a realizar las saturaciones en cada factor, donde se va a buscar o se puede considerar como miembro influyente de

un factor aquel que tenga una saturación mayor a 0.3, considerando que un factor, no puede tener menos de 3 preguntas; en caso contrario, tocará eliminar dicho factor. En la tabla 3, se puede observar que las preguntas 2 y 13, no están dentro de los factores interpretados, por tener una saturación menor a lo especificado.

Tabla 3: Matriz de factores interpretados

Factor 1	(ML1)	Factor 2	(ML2)
P1	0.32	P4	0.54
P3	0.38	P5	0.60
P8	0.81	P6	0.66
P9	0.73	P7	0.45
P10	0.49		
P11	0.60		
P12	0.41		
P14	0.50		
P15	0.41		

Nota. Fuente:(George & Mallery, 2024)

El factor 1, representa la integración de las herramientas de inteligencia artificial como apoyo académico en el aprendizaje de estadística descriptiva y se lo puede denominar como “uso y percepción académica de la inteligencia artificial”.

El factor 2, refleja el nivel de familiaridad, capacitación y adaptación tecnológica hacia herramientas de IA; se lo puede denominar “competencia percibida en el uso de la IA”.

3.4.5. Validación del análisis factorial exploratorio

En la validación, la confiabilidad interna del instrumento fue evaluada mediante el coeficiente Alfa de Cronbach, donde se considera su interpretación en la siguiente tabla.

Tabla 4: Interpretación del Alfa de Cronbach

Alfa	Interpretación
	Excelente
	Muy bueno
	Aceptable
	Moderado
	Deficiente

Nota. Fuente: Walter Jácome Vélez. (2026)

Las cargas factoriales obtenidas evidencian que comparten una dimensión común, relacionada con la aceptación; el análisis de confiabilidad muestra un alfa de Cronbach, de 0.78, indicando una adecuada consistencia interna y confiando en que los ítems que conforman este factor presentan una coherencia estadística, lo cual es un modelo aceptable.




Figura 10. Validación del Alfa de Cronbach para el factor 1. Fuente: Walter Jácome Vélez (2026).

El análisis de confiabilidad presentó un Alfa de Cronbach de 0.66, considerado aceptable para estudios exploratorios en ciencias sociales, lo cual indica una con-

sistencia interna moderada entre los ítems que conforman este factor y evidencia una adecuada relación conceptual dentro de la estructura del instrumento.

```

raw_alpha std.alpha G6(smc) average_r S/N ase mean sd median_r
0.66      0.66      0.6      0.33  2 0.045 2.6 0.95 0.33

95% confidence boundaries
lower alpha upper
Feldt 0.56 0.66 0.74
Duhachek 0.57 0.66 0.75

Reliability if an item is dropped:
raw_alpha std.alpha G6(smc) average_r S/N alpha se var.r med.r
p4 0.60 0.61 0.51 0.34 1.5 0.056 0.00424 0.35
p5 0.59 0.59 0.49 0.32 1.4 0.057 0.00059 0.32
p6 0.57 0.57 0.47 0.30 1.3 0.060 0.00130 0.31
p7 0.62 0.62 0.52 0.35 1.6 0.053 0.00173 0.34

Item statistics
n raw.r std.r r.cor r.drop mean sd
p4 155 0.70 0.70 0.52 0.43 2.4 1.3
p5 155 0.72 0.71 0.56 0.45 2.5 1.4
p6 155 0.71 0.73 0.60 0.49 2.8 1.2
p7 155 0.70 0.68 0.50 0.41 2.7 1.4

Non missing response frequency for each item
1 2 3 4 5 miss
p4 0.39 0.13 0.23 0.19 0.06 0
p5 0.40 0.07 0.22 0.22 0.09 0
p6 0.25 0.03 0.41 0.28 0.03 0
p7 0.33 0.11 0.20 0.25 0.11 0

```

Figura 11. Validación del Alfa de Cronbach para el factor 2. Fuente: Walter Jácome Vélez (2026).

3.5. Análisis factorial confirmatorio

Se realiza la técnica multivariante, como el análisis factorial confirmatorio, para verificar una estructura teóricamente ajustada o realizada ante un análisis factorial exploratorio. Se ajustan los datos observados; la tarea es confirmar la relación existente entre las variables observadas, y los factores latentes o constructos que se desean medir.

3.5.1. Estructura factorial

La estructura que se presenta es un modelo factorial de dos factores, correlacionados, derivado del análisis factorial exploratorio, que se realizó a priori, se busca una solución coherente, que no refleje indicios de invalidez.




Figura 12. Estructura factorial. Fuente: Walter Jácome Vélez (2026).

Las cargas interfactoriales: lo único que se desea es que no existan valores cercanos a 1; su valor es 0.4, esto representa su correlación, indicando que ambas dimensiones están relacionadas moderadamente entre sí. Las cargas de cada pregunta hacia su respectivo factor: no se observan indicios de invalidez; la estructura factorial evidencia una adecuada organización de los ítems

en dos dimensiones claramente diferenciadas. En términos metodológicos, esta estructura fortalece la validez de constructo del cuestionario y demuestra que el instrumento posee una organización conceptual consistente para evaluar tanto el uso académico de la Inteligencia Artificial como la familiaridad tecnológica de los estudiantes.

```
lavaan 0.6-21 ended normally after 46 iterations

Estimator                      ML
Optimization method            NLMINB
Number of model parameters      27

Number of observations          155

Model Test User Model:

Test statistic                  114.811
Degrees of freedom              64
P-value (Chi-square)           0.000

Parameter Estimates:

Standard errors                 Standard
Information                     Expected
Information saturated (h1) model Structured
```

Figura 13. Resumen resultado del AFC. Fuente: Walter Jácome Vélez (2026).

El estimador de máxima verosimilitud, realiza un modelo de optimización; además, se observa que el test estadístico es de 114.811 para un Ji-cuadrado, con un p-valor de 0. Se puede concluir que es significativo, que el modelo alcanzó el nivel de significancia.

3.5.2. Conjunto de modelos lineales

De cada uno de los factores, se puede describir el conjunto de modelo lineal. Para expresar el modelo lineal único, se suman todos los indicadores ponderados por sus cargas factoriales estandarizadas.

Factor 1: Uso y percepción académica de la inteligencia artificial

$$F_1 = 0.370(p_1) + 0.391(p_3) + 0.805(p_8) + 0.730(p_9) + 0.527(p_{10}) + 0.587(p_{11}) + 0.475(p_{12}) + 0.448(p_{14}) + 0.385(p_{15}) + \varepsilon \quad (3)$$

Donde:

- p_1 Frecuencia de estudio fuera de clase
- p_3 Uso de la IA para resolver tareas
- p_8 La IA ha mejorado mi desempeño académico.
- p_9 Recorro a la IA cuando no entiendo explicaciones.
- p_{10} La IA proporciona respuestas claras.
- p_{11} Confío en los resultados obtenidos con IA.
- p_{12} La IA complementa los contenidos impartidos.
- p_{14} Percepción de dificultad de la estadística descriptiva
- p_{15} Frecuencia de estudio en grupo

Factor 2: competencia percibida en el uso de la IA

$$F_2 = 0.543(p_4) + 0.592(p_5) + 0.593(p_6) + 0.571(p_7) + \varepsilon \quad (4)$$

Donde:

- p_4 La IA ayuda a comprender conceptos estadísticos.

- p_5 Comodidad en el uso de herramientas de IA
- p_6 Orientación previa sobre IA
- p_7 Frecuencia de consulta de herramientas de IA

Latent variables:						
	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
factor1 =~						
p1	1.000				0.609	0.370
p3	1.133	0.345	3.284	0.001	0.690	0.391
p8	2.314	0.542	4.270	0.000	1.410	0.805
p9	2.181	0.521	4.189	0.000	1.329	0.730
p10	1.436	0.380	3.780	0.000	0.875	0.527
p11	1.679	0.427	3.932	0.000	1.023	0.587
p12	1.380	0.381	3.619	0.000	0.840	0.475
p14	1.117	0.317	3.519	0.000	0.680	0.448
p15	1.115	0.343	3.255	0.001	0.679	0.385
factor2 =~						
p4	1.000				0.727	0.543
p5	1.160	0.261	4.448	0.000	0.844	0.592
p6	0.967	0.217	4.449	0.000	0.703	0.593
p7	1.118	0.255	4.381	0.000	0.813	0.571
Covariances:						
	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
factor1 =~ factor2	0.175	0.068	2.575	0.010	0.396	0.396

Figura 14. Factores del conjunto de modelos lineales del AFC. Fuente: Walter Jácome Vélez (2026).

3.5.3. Índices de ajustes globales

La interpretación de saber si es aceptable o no el análisis factorial confirmatorio,

depende de los índices de ajustes, donde se analizan indicadores globales, bajo el criterio de valores estandarizados.

npar	fmin	chisq	df	pvalue
27.000	0.370	114.811	64.000	0.000
baseline.chisq	baseline.df	baseline.pvalue	cfi	tli
475.480	78.000	0.000	0.872	0.844
nnfi	rfi	nfi	pnfi	ifi
0.844	0.706	0.759	0.622	0.877
rni	logl	unrestricted.logl	aic	bic
0.872	-3611.358	-3553.952	7276.716	7358.889
ntotal	bic2	rmsea	rmsea.ci.lower	rmsea.ci.upper
155.000	7273.427	0.072	0.050	0.092
rmsea.ci.level	rmsea.pvalue	rmsea.close.h0	rmsea.notclose.pvalue	rmsea.notclose.h0
0.900	0.051	0.050	0.267	0.080
rnr	rnr_nomean	srnr	srnr_bentler	srnr_bentler_nomean
0.192	0.192	0.073	0.073	0.073
crmr	crmr_nomean	srnr_mplus	srnr_mplus_nomean	cn_05
0.079	0.079	0.073	0.073	113.965
cn_01	gfi	agfi	pgfi	mfi
126.846	0.903	0.862	0.635	0.849
ecvi				
1.089				

Figura 15. Índices de ajustes globales del AFC. Fuente: Walter Jácome Vélez (2026).

Estos índices presentan ajustes aceptables, pero no excelentes, por lo que se puede considerar válido el análisis factorial confirmatorio.

4. Discusión

Los resultados obtenidos coinciden con los reportados en el estudio realizado en la Universidad Privada Domingo Savio, al evidenciar que el uso de la inteligencia artificial representa un recurso potencial para fortalecer el proceso de enseñanza y aprendizaje y favorecer el rendimiento académico de los estudiantes universitarios, la muestra aleatoria fue de 326 estudiantes. Por medio de un enfoque cuantitativo y transversal, se recolectaron datos que permitieron identificar las principales herramientas de IA empleadas, entre las cuales destaca ChatGPT como la más utilizada. Donde un 57% de los estudiantes reportó una mejora en su desempeño, mientras que un 41% no percibió cambios significativos (Guzmán et al., 2024), existen diferencias relevantes en el enfoque metodológico; la presente investigación profundizó en la validación de las dimensiones que explican dicho fenómeno mediante técnicas de análisis multivariante.

Dentro del proceso de aprendizaje de educación y el uso de la inteligencia artificial, el trabajo realizado en la Universidad Nacional, José Faustino Sánchez Carrión, determinó una relación estadísticamente significativa entre el uso de la inteligencia artificial y el proceso de aprendizaje de los estudiantes, evidenciada mediante un coeficiente de correlación de Spearman de 0.771 ($p < 0.05$). Estos resultados son de la investigación realizada por (Lopez Gomero, 2025). Este enfoque proporciona

una explicación más profunda sobre los componentes que influyen en la percepción y utilización de estas herramientas, lo que constituye un aporte metodológico para futuras investigaciones. Ambos estudios coinciden en que la inteligencia artificial posee un importante potencial para mejorar los procesos de aprendizaje y el rendimiento académico; sin embargo, sus beneficios dependen del nivel de integración pedagógica, de las competencias digitales desarrolladas por los estudiantes y de un uso responsable y ético de estas tecnologías.

Considerando los resultados mediante la técnica de reducción de dimensiones, por medio de un análisis factorial exploratorio, y un análisis factorial comprobatorio, tales hallazgos tienen una metodología similar con una investigación realizada, por (Espitia-Cubillos & Rodríguez-Carmona, 2023). Donde utilizan técnicas multivariantes usadas en el ámbito de la responsabilidad social universitaria, Se realiza una revisión bibliográfica de los textos referentes a la responsabilidad social universitaria. Posteriormente, se analizan estadísticamente para reportar las tendencias en el campo. En la literatura estudiada, los autores emplean métodos estadísticos cuantitativos que permiten diagnosticar la implementación de la Responsabilidad Social Universitaria, y el 83% de los estudios corresponden a la aplicación de técnicas estadísticas multivariantes.

Un trabajo interesante realizado por (A. V. Sánchez et al., 2026), la validación de un cuestionario para diagnosticar en la integración pedagógica de la inteligencia artificial, El cuestionario inicial se componía de 72 ítems. Se realizó un análisis exploratorio y, posteriormente, un análisis

confirmatorio, dando como resultado un instrumento configurado por cinco dimensiones: conocimientos y creencias sobre la IA en educación, competencias digitales docentes, formación inicial y continua, usos pedagógicos y didácticos de la IA, y actitudes éticas y reflexivas hacia la IA, lo cual dentro de su metodología es similar a la de este trabajo, ya que realiza un análisis factorial exploratorio y confirmatorio para la reducción de dimensiones.

5. Conclusiones

Para los factores del análisis factorial exploratorio, el Raw-Alfa que es la prueba de validez o constructo factorial, debe estar entre los rangos de 0.7 – 0.9 para considerarse aceptable. Para el primer factor, es de 0.78, valor que indica una buena confiabilidad; para el factor 2, el Raw-Alfa, o Alfa de Cronbach, es de 0.66, es considerado aceptable para estudios exploratorios y escalas de pocos ítems, además de que ningún ítem mostró evidencias de afectar negativamente la consistencia interna del constructo, para ambos factores.

Dentro del análisis factorial confirmatorio, los indicadores o los índices de ajustes globales, tanto el CFI (comparativ fit index); TLI (Tocker & Lewis index); NFI (normet fit index); RMSEA (root mean square error of approximation); SRMR (Standardized root mean square residual), presentan un ajuste aceptable a los datos. El RMSEA = 0.072 se encuentra dentro del rango recomendado, menor a 0.08, indicando un error de aproximación razonable, y una adecuada estructura factorial.

Los niveles para validar el análisis factorial confirmatorio, están por debajo del criterio óptimo; sin embargo, los criterios se aproximan a los niveles aceptables para los estudios exploratorios y procesos iniciales de validación de instrumentos, considerando la encuesta de 155 participantes y la naturaleza multidimensional del constructo evaluado.

El modelo factorial confirmatorio presentó un ajuste global aceptable (RMSEA = 0.072; SRMR = 0.073), evidenciando una adecuada representación de los datos empíricos. Aunque los índices incrementales CFI = 0.872, TLI = 0.844 y NFI = 0.759 no alcanzaron el valor óptimo de 0.90, los resultados obtenidos respaldan la validez de la estructura bifactorial identificada y permiten considerar el instrumento como metodológicamente adecuado para fines de investigación y validación en contextos educativos.

6. Contribución de los autores

WJJV: Recolección de datos, análisis de resultados

JCLR: discusión, revisión final del artículo.

9. Referencias

- Acero, G. D. F., & Alba, M. A. A. (2025). Authorship in the Age of ChatGPT: New Challenges for Copyright Law; [A autoria na era do ChatGPT: novos desafios para o direito autoral]; [La autoría en tiempos de ChatGPT: nuevos desafíos para el derecho de autor1]. *Revista Iberoamericana de La Propiedad Intelectual*, (23), 227–303. <https://doi.org/10.26422/RIPI.2025.2300.flo>
- Barrientos Durán, C., Bustos Aguayo, J. M., Vanegas Rico, M. C., & Pérez Durán, J. (2024). Análisis factorial confirmatorio de la escala de desempeño laboral en profesionistas del Valle de México durante el confinamiento por COVID-19. *Revista Gestión de las Personas y Tecnología*, 17(49), 111–130.
- Comolli, J. A., Cappello Villada, J. S., Méndez Galarza, S., García, L. D. M., & Obregón, G. R. E. (2026). Student dropout in the Veterinary Science program at the National University of the Northeast; [Deserción estudiantil en la carrera de Ciencias Veterinarias de la Universidad Nacional del Nordeste]. *Revista Veterinaria*, 37, 1 – 7. <https://doi.org/10.30972/vet.3719057>
- Espitia-Cubillos, A. A., & Rodríguez-Carmona, E. (2023). Técnicas estadísticas multivariantes usadas en el ámbito de la responsabilidad social universitaria: una revisión del estado del arte. *Prospectiva*, 21(2).
- Garza, L. M. G. de la. (2024). ARTIFICIAL INTELLIGENCE AND HIGHER EDUCATION. Possibilities, acceptable risks and limits that should not be crossed.; [INTEL·LIGÈNCIA ARTIFICIAL I EDUCACIÓ SUPERIOR. Possibilitats, riscos acceptables i limitis que no s’han de traspasar.]; [INTELIGENCIA ARTIFICIAL Y EDUCACIÓN SUPERIOR. Posibilidades, riesgos aceptables y límites que no se deben traspasar]. *Revista de Educación y Derecho*, (2-Extraordinario). <https://doi.org/10.1344/REYD2024.2-Extraordinario.49175>
- George, D., & Mallery, P. (2024). *IBM SPSS Statistics 29 step by step: A simple guide and reference*. Routledge.
- Guzmán, A. G. Z., Jara, P. M. F., Pardo, S. O., & Coca, R. G. (2024). Percepción y uso de la inteligencia artificial en la educación superior: Correlación con el rendimiento académico en estudiantes universitarios. *YUYAY: Estrategias, metodologías y didácticas educativas*, 4(1), 100–120.
- Jiménez, J. U. (2019). *Introducción a R y RStudio*.
- Leddy, M., & McCreanor, N. (2024). Exploring how Education can Leverage Artificial Intelligence for Social Good. *Proceedings of the European Conference on Innovation and Entrepreneurship, ECIE*, 19(1), 1041–1048. <https://doi.org/10.34190/ecie.19.1.2906>
- Lopez Gomero, R. J. (2025). *Inteligencia artificial y el proceso de aprendizaje de los estudiantes de la Facultad de Educación de la Universidad Nacional José Faustino Sánchez Carrión–2024*.
- Pérez, E. R., & Medrano, L. A. (2010). Análisis factorial exploratorio: bases conceptuales y metodológicas. *Revista Argentina de Ciencias del Comportamiento (RACC)*, 2(1), 58–66.

Sánchez, A. V., Fuentes, E. P., & Queiroz, S. F. (2026). Validación de un cuestionario para diagnosticar competencias docentes en la integración pedagógica de la inteligencia artificial. *RIED-Revista Iberoamericana de Educación a Distancia*, 29(2).

Sánchez, K. M. A., & Sandoval, J. L. S. (2024). EVOLUTION OF MULTIVARIATE ANALYSIS METHODS IN THE FIELD OF MANAGEMENT SCIENCES; [La evolución de los métodos de análisis multivariante en el campo de las ciencias de la administración]. *Revista Academia and Negocios*, 10(2), 239–250. <https://doi.org/10.29393/RAN10-15EMML20015>

Tan, S. (2023). Harnessing Artificial Intelligence for Innovation in Education. In *Learning Intelligence: Innovative and Digital Transformative Learning Strategies: Cultural and Social Engineering Perspectives*. https://doi.org/10.1007/978-981-19-9201-8_8

Copyright (c) 2027. Walter Joffred Jácome Vélez, Juan Carlos López Ruano.



Este es un artículo de acceso abierto, bajo licencia [Creative Commons](#)
(CC BY 4.0) de Atribución 4.0 Internacional