

Caracterización del Uso Académico de Chatbots de Inteligencia Artificial en Alumnos de Educación Superior, por Medio del Análisis Factorial

Characterization of the Academic Use of Artificial Intelligence Chatbots in Higher Education Students, through Factor Analysis

Martos-Martínez. C. E.¹

Datos de Adscripción:

¹ Martos Martínez, Carlos Eduardo
Tecnológico Nacional de México/Instituto Tecnológico Superior de Lerdo.
Ciudad Lerdo, Durango. México.
ROR ID: <https://ror.org/00davy38>
ROR ID: <https://ror.org/04bjbt12>
carlos.mm@itslerdo.edu.mx
<https://orcid.org/0000-0002-0144-9745>

Resumen – La presente tuvo como objetivo categorizar el uso de las aplicaciones de IA en las asignaturas por parte de los estudiantes de educación superior. Esta emanó de la interrogante: “¿Cómo categorizar el uso de las aplicaciones y los chatbots de IA por parte de los estudiantes de educación superior?”. Para su realización, se empleó un paradigma positivista cuantitativo, correlacional, no experimental, se aplicó un instrumento de evaluación de 48 ítems a una muestra de 360 estudiantes de ingeniería y licenciatura en 2025, efectuándose un análisis factorial exploratorio y confirmatorio. Los resultados arrojaron alta fiabilidad (alfa de Cronbach de 0.966), el índice KMO de 0.944, la prueba de esfericidad de Bartlett fue un chi-cuadrado ≈ 17932 y $p < 0.001$, aceptando H_0 , denotando excelente adecuación de los datos para justificar el análisis factorial exploratorio, realizándolo por el método de Componentes Principales y un método de rotación Varimax normalizado, con cargas factoriales superiores a 0.70. Se extrajeron ocho factores retenidos que demuestran que los estudiantes utilizan las aplicaciones y chatbots de inteligencia artificial como apoyo en materias de física, tienen una concepción clara del funcionamiento y el uso de estas, su empleo como auxiliar en el aprendizaje de idiomas, la búsqueda de información y redacción de textos, la creación de productos multimedia, matemáticas básicas, desarrollo de programas de cómputo y traducción de documentos y presentaciones.

Palabras Clave: Inteligencia Artificial, IA, chatbots, categorización, análisis factorial

Abstract - The objective of this research was to categorize the use of AI applications in subjects by higher education students. This emanated from the question “how to categorize the use of AI applications and chatbots by higher education students?” To carry out the research, a quantitative, correlational, non-experimental positivist approach was used. A 48-item evaluation instrument was

applied to a sample of 360 engineering and undergraduate students in 2025, and an exploratory and confirmatory factor analysis was conducted. The results showed high reliability (Cronbach's alpha of 0.966), the KMO index presented a value of 0.944; Bartlett's sphericity test (significance) was chi-squared ≈ 17932 and $p < 0.001$, accepting H_0 and denoting excellent data appropriateness to justify the exploratory factor analysis, carried out using the Principal Components method and a Normalized Varimax rotation method, highlighting factor load levels greater than 0.70. Eight retained factors were obtained, which demonstrate that students use Artificial Intelligence applications and chatbots as support in physics subjects, have a clear conception of their operation and use, use them as an aid in language learning, the search for information and writing texts, create multimedia products, use them in basic mathematics, development of computer programs, and in the translation of documents and presentations.

Keywords: AI, Artificial Intelligence, categorization, chatbots, factor analysis, higher education.

I. INTRODUCCIÓN

La Inteligencia Artificial (IA) y, específicamente, los chatbots de IA están transformando rápidamente el panorama de la educación, desempeñando un papel fundamental en la configuración de cómo se imparte y adquiere el conocimiento. Son una herramienta con gran potencial para facilitar el aprendizaje, permitiendo a los docentes adaptar sus modelos de enseñanza para incrementar el nivel académico de los estudiantes. Si bien la IA tiene la capacidad de transformar la educación de manera importante, también plantea serias preocupaciones que no deben ser ignoradas. Entre estas preocupaciones se encuentran la privacidad de los datos de los estudiantes, la gran cantidad de datos que requieren estos sistemas, la protección de los datos personales y la información confidencial, los sesgos algorítmicos, la alta dependencia de esta tecnología, la desigualdad en el acceso a ella y la falta de directrices y regulaciones para su uso (Giraldo, 2023). Profundizar en la comprensión de la Inteligencia Artificial en un contexto de Educación Superior permitirá encontrar brechas y oportunidades para mejorar la formación académica, así como para atender los retos éticos y prácticos que se plantean con su implementación en las aulas.

1.1 Inteligencia Artificial en la Educación Superior.

La utilización predominante de tecnologías basadas en la inteligencia artificial se observa principalmente en el ámbito de la educación superior. Como lo indican Crompton y Song (2021), el número predominante de investigaciones sobre el uso de la IA se realiza en estudiantes de licenciatura, en una cantidad mayor que en estudiantes de posgrado, aunque esta tecnología tiene una relevancia sustancial en ambos entornos educativos. (p11).

1.2 Empleo de asistentes de IA en sistemas de tutoría.

Los asistentes de IA, como los chatbots, están demostrando su eficacia en la tutoría personalizada. Pappas & Drigas, (2016), mencionan que un sistema de tutoría Inteligente consta generalmente de cuatro partes: Dominio experto, es el conocimiento de la materia a aprender por el sistema, dominio de experiencia pedagógica, que es el mecanismo de control que guía la enseñanza, el Modelo de alumno, que se encarga de registrar toda la información relevante sobre el alumno y crear un perfil de aprendizaje individual para cada una, y la Interfaz que interactúa con el alumno siguiendo las instrucciones del modelo pedagógico.

1.3 Utilización de asistentes de IA en la enseñanza de matemáticas y ciencias.

Wang et al. (2023) han implementado plataformas de entorno de aprendizaje interactivo, como ACTIVE Math asistido por IA, MathIA y Why2Atlas, para administrar los logros de aprendizaje, realizar un seguimiento del rendimiento, mejorar las herramientas de enseñanza y apoyar la comunicación y retroalimentación entre instructores y estudiantes internacionales de diferentes niveles y materias (p5). Crompton & Song, (2021) mencionando a Khalfallah y Slama (2018), en la Universidad de Sousse, Túnez se construyó un sistema llamado LabTutor para estudiantes de ingeniería que se desempeñó como un instructor experimentado al permitir a los estudiantes acceder y realizar experimentos en equipos de laboratorio mientras se adaptaba al perfil de cada estudiante. (p17).

1.4 Utilización de asistentes de IA en el desarrollo de programas de computación.

La implementación de asistentes de IA en el desarrollo de programas informáticos permite a los estudiantes aprender de manera más dinámica y personalizada, facilitando la adquisición de habilidades técnicas esenciales para el desarrollo de software o de aplicaciones de cómputo. Terán (2023, p. 8) menciona a la IA como una tecnología prometedora para mejorar la enseñanza y el aprendizaje de la programación, destacando el uso de ChatGPT. A su vez, Portella-Cleves & Rodríguez-Hernández (2023, p. 11) postulan un Plan de Aprendizaje Activo Integrando la IA en la Educación de Programación que permita a los estudiantes participar activamente en un eficiente proceso de desarrollo de software, enfatizando la resolución de problemas, la colaboración y la integración de herramientas de IA en el aula.

1.5 Utilización de asistentes de IA búsqueda de información y redacción de textos.

Los asistentes de inteligencia artificial pueden ayudar a los

estudiantes a estructurar sus ideas, mejorar la gramática y proporcionar retroalimentación instantánea, facilitando el proceso de escritura y fomentando la creatividad. Wang et al., (2023) comentan que las aplicaciones impulsadas por IA, como Grammarly, Ecree y PaperRater, ofrecen detección de plagio, calificación y mejora de la escritura, entre otras funciones administrativas que pueden beneficiar a los estudiantes internacionales (p5). Morantes, (2023) categoriza la experiencia en el uso de la IA para la producción de artículos científicos e investigaciones en tres categorías de uso: (a) comunicación científica (ChatGPT 3.5) para realizar búsquedas sistemáticas y generar artículos científicos/investigaciones (objeto o idea, hipótesis, interrogantes, método de investigación y proyección de conclusiones basadas en la hipótesis y el método); (b) construcción de redes referenciales sobre el objeto de estudio (Litmaps, Iris, Connected papers y Research rabbit); y (c) análisis de contenido (Humata y Chatpdf). (p11).

1.6 Utilización de asistentes de IA en la creación de productos multimedia.

El uso de la IA en la elaboración de productos multimedia en la educación no solo incentiva la creatividad de los alumnos, sino que también les proporciona herramientas para desarrollar habilidades técnicas relevantes en un entorno digital. Respecto a las aplicaciones multimedia que se pueden generar con la inteligencia artificial, Anantrasirichai & Bull (2020, p. 608) analizan cómo se han empleado las tecnologías de IA tanto para apoyar el proceso creativo para desarrollar productos como guion y generación de películas, generación de música, generación de imágenes, animación, realidad aumentada, virtual y mixta (VR, AR, MR) y deepfakes.

1.7 Utilización de asistentes de IA para el aprendizaje de idiomas

Los chatbots se utilizan para facilitar la adquisición de conocimientos básicos en algunas áreas temáticas, por ejemplo, para probar y reforzar la memorización de definiciones clave (Lee et al., 2020). La investigación muestra que este tipo de chatbot resulta beneficioso para los estudiantes de idiomas. Como lo menciona Kim (2021), citado por O'Dea (2023, p. 5), con respecto al uso de un chatbot para enseñar inglés a estudiantes universitarios coreanos, se muestra que los estudiantes que usaron el chatbot lograron un rendimiento de habla mucho mejor en comparación con aquellos que no lo hicieron.

1.8 Desarrollo de la investigación.

La investigación que se presenta se llevó a cabo en la Universidad Politécnica de Gómez Palacio, ubicada en el ejido El Vergel, del municipio de Gómez Palacio, Durango, durante los meses de septiembre a diciembre de 2025.

II. PARTE TÉCNICA DEL ARTÍCULO

2.1 Descripción de dimensiones y variables.

Para la presente investigación de corte cuantitativo, se elaboró un instrumento de 48 reactivos para la recopilación de

datos, destinado a medir el mismo número de variables. Para la determinación de estas, se revisó el marco teórico, tanto en los antecedentes como en la literatura encontrada en relación al funcionamiento y a la aplicación de la IA en educación superior.

2.2 Sujeto de estudio, universo, población y muestra.

El universo de sujetos de estudio para la investigación son los estudiantes de los municipios de Gómez Palacio y Lerdo. Respecto a la población considerada para la investigación, se consideró el total de la matrícula inscrita en la Universidad Politécnica de Gómez Palacio para el ciclo septiembre-diciembre de 2025, que, de acuerdo con los datos del reporte de la Junta Directiva, es de 1620. Para esta investigación, se consideró una muestra probabilística, ya que todos los elementos de la población tuvieron la misma posibilidad de ser escogidos, aleatoria simple, debido a que cada sujeto solamente aplicaría el instrumento de evaluación una sola vez (Hernández-Sampieri et al., 2014, p. 181).

El tamaño de la muestra se estimó con la siguiente expresión (Krejcie R, Morgan D., 1970, p. 607):

$$S = \frac{X^2 NP(1 - P)}{d^2(N - 1) + X^2 P(1 - P)} \quad (1)$$

donde:

S: Tamaño de muestra

N: Número de población.

P: Proporción de la población que por la construcción de la tabla se determina como 0.50.

d: Grado de precisión reflejado como la cantidad de error que puede ser permitido en la fluctuación de una proporción de la muestra p relacionada con la proporción de la población P menos el valor de d, siendo 0.05 en los cálculos de entradas de la tabla, dando igual a ± 1.96 sp.

$X^2=+$: Valor de chi-cuadrado (tabla) para 1 grado de libertad en el nivel de confianza deseado (3,841).

Con la ecuación (1) y los parámetros $P=0.5$, $d=0.05$, $X^2=3.84$ y $N=1620$, se obtiene un tamaño de la muestra S de 311.

2.3 Instrumento de Investigación.

El diseño del instrumento fue desarrollado después de revisar cada una de las variables y operacionalizarlas, para de allí realizar 48 reactivos de intervalo con una escala del 0 al 100. Para la construcción del instrumento de investigación, se realizó un proceso de operacionalización, codificación y establecimiento de los niveles de medición de las variables (Hernández Sampieri et al., 2014, p. 211). Una vez realizado este proceso, se elaboró el instrumento de medición en un documento de texto en Microsoft Word a manera de cuestionario, en donde se adecuó la operacionalización en reactivos los cuales, responderían los sujetos de investigación. El instrumento se aplicó durante los días del 13 al 17 de octubre de 2025 a 363 estudiantes, los cuales lo respondieron mediante su dispositivo móvil utilizando la

aplicación Google Forms, como se muestra en la Figura 1. Para asegurar la aleatoriedad de la muestra, la aplicación se llevó a cabo durante la clase de idiomas, ya que en esta se encuentran alumnos de todas las carreras.


2.4 Análisis de los datos.

Los resultados obtenidos de la aplicación del instrumento de investigación de 48 variables a 363 sujetos fueron extraídos, integrados en una base de datos, la cual fue depurada y preparada para su posterior análisis, eliminando 3 instrumentos con datos irreconocibles, dando un total de 360 instrumentos aplicados.

Las herramientas utilizadas para el análisis fueron: Microsoft Excel, StatSoft Statistica 12 e IBM SPSS 31.

Figura 1

Captura de pantalla de formulario de instrumento final.



2.5 Confiabilidad.

Como lo comentan Hernández Sampieri et al., 2014 (p. 200), la confiabilidad de un instrumento de medición es la medida en que este, al ser aplicado de forma repetida al mismo individuo u objeto, produzca los resultados. Para ello se hace uso del coeficiente alfa de Cronbach, el cual evalúa el grado en que los ítems de un instrumento están correlacionados. Es el promedio de las correlaciones entre los ítems de un instrumento. El valor del coeficiente es de 0 a 1. Un valor mínimo aceptable del coeficiente es 0.70; valores menores denotan que la consistencia interna de la escala utilizada es baja, valores entre 0.71 y 0.80 son aceptables; entre 0.81 y 0.90 son buenos; y superiores a 0.90 son excelentes. El cálculo del coeficiente alfa de Cronbach es (De Los Heros M, 2024, p. 42) realiza con la ecuación:

$$\alpha = \frac{K}{K - 1} \left[1 - \frac{\sum_{i=1}^K S_i}{S_t} \right] \quad (2)$$

donde:

α : Coeficiente Alfa de Cronbach.

K: Número de ítems.


S_i : Varianza de cada ítem.

S_t : Varianza de la suma de todos los ítems.

El resultado arrojado por el Software Statistica 12 con el que se analizaron los datos para el Alpha de Cronbach es 0.966, como se observa en la Figura 2, por lo que el instrumento de evaluación tiene alta confiabilidad.

Figura 2

Captura de pantalla del Alpha de Cronbach calculada con Statistica 12.



2.6 Estadística descriptiva.

Se aplicaron un total de 360 instrumentos de evaluación de un total de 311 requeridos para cumplir con el estimado de tamaño de la muestra, principalmente en un rango de edad de 15 a 20 años, con un 81% de los encuestados. En la Tabla 1 se observa la distribución de la aplicación por edades.

Tabla 1


Distribución de aplicaciones por edad.

Rango de edad	Total	porcentaje
15 - 20	291	81%
20 - 25	65	18%
25 - 30	3	1%
Mas de 30	1	0.28%
	360	100%

En lo que respecta al género, la distribución de la aplicación fue de 49% hombres, 50% mujeres y un 1% mencionó como género "otros". A su vez, en lo concerniente a la trayectoria académica, el 41% de los alumnos que aplicaron el instrumento pertenecieron al primer cuatrimestre, seguidos por los de séptimo con un 37% y los de cuarto cuatrimestre con un 22%. Respecto al rendimiento académico de los estudiantes que contestaron el instrumento de evaluación, en la figura se aprecia que el 54% de los estudiantes que contestaron el instrumento se encuentran en un rango de promedio entre 9.0 y 9.4.

Figura 2

Gráfica de distribución por promedio general. Elaboración propia.



La Figura 3 muestra la gráfica de la aplicación de los estudiantes por materias reprobadas, en donde el 68% no tiene materias reprobadas.

Figura 3

Gráfica de distribución por materias reprobadas. Elaboración propia.



2.7 Análisis univariable.

Se realizó un ejercicio de análisis univariable utilizando las medias aritméticas de cada una de las variables de los 48 ítems de los instrumentos contestados por los 360 sujetos de investigación. Los resultados que se muestran en la Tabla 2 de media de medias y desviación estándar fueron calculados por el software Statistica 12.

Tabla 2

Resultados de la media, valores mínimos, máximos y desviación estándar de las medias.

Datos válidos	Media de medias	Valor Mínimo	Valor máximo	S
48	36.21	14.09	68.67	13.64

2.8 Análisis factorial.

El análisis factorial es una técnica estadística ampliamente empleada en psicología y ciencias sociales diseñada para estimar características de una población total mediante el análisis de variables observadas y sus interrelaciones. Sirve como una herramienta de diagnóstico crucial para evaluar datos frente a modelos teóricos y constructos esperados (Zeynivandnezhad et al., 2019, p59). Mediante el análisis factorial se pretende definir un modelo que, como señala González, C., Et al (2013, p697), incorpore los factores comunes que interesan, entendidos como aquellos que permiten explicar la totalidad de las variables y que no pueden observarse ni medirse directamente. Por ello, es necesario determinar si el modelo que hemos elaborado con el número y el significado de los factores se ajusta a la realidad observada, utilizando para ello los datos. Para eso, se formula un modelo en el que se incorpora un factor específico para cada variable; dicho factor recoge la variabilidad que no logra ser explicada por el conjunto de los factores comunes. Así, en un modelo con n variables observadas y dos factores comunes:

$$\begin{aligned}
 X_1 &= \lambda_{11}F_1 + \lambda_{12}F_2 + e_1 \\
 X_2 &= \lambda_{21}F_1 + \lambda_{22}F_2 + e_2 \\
 &\dots \dots \dots \dots \dots \\
 X_n &= \lambda_{n1}F_1 + \lambda_{n2}F_2 + e_n
 \end{aligned}
 \quad (3)$$

En el modelo, se denominan saturaciones a los coeficientes λ_{ij} , que se estiman: λ_{ij} representa la saturación de X_i en F_j . Para que el análisis sea válido, las variables deben ser cuantitativas y estar correlacionadas, de lo contrario, no existiría información compartida explicable mediante factores comunes. Existen varios procedimientos para la determinación de los coeficientes, siendo uno de ellos el de componentes principales. La varianza de cada una de las variables X_i se expresa de la siguiente forma:

$$\sigma^2 = \lambda_{i1}^2 + \lambda_{i2}^2 + \varphi_i \quad (\varphi_i: \text{Varianza de la componente específica}) \quad (4)$$

En consecuencia, la varianza de cada variable es igual a la suma de los cuadrados de las saturaciones, magnitud que se denomina comunalidad, más un componente residual o especificidad.

Los autovalores (eigenvalores) son escalares que miden la cantidad de varianza total en el conjunto de datos original que puede explicar un factor específico. Son un índice esencial para determinar cuántos factores deben dejarse e interpretarse en el modelo final. Cuando el número de factores comunes es superior a 1, la estimación de los coeficientes del modelo, es decir, de las saturaciones, no queda determinada; por tanto, existen infinitas soluciones. Encontrada una solución, se obtiene una transformación mediante rotación que es una solución válida. Por lo tanto, es posible buscar dentro de muchas soluciones existentes, aquellas que permiten una mejor interpretación del modelo para que, finalmente, buscar que cada factor presente pocas saturaciones altas y el resto muy bajas, lo cual permite interpretar los factores en función de las variables; además, se requiere que cada variable esté muy saturada en un único factor, lo que facilita la interpretación de las variables en términos de los factores. Por último, los factores deben ser distintos, ya que se asume que explican aspectos diferentes.

2.9 Análisis factorial Exploratorio.

Se elaboró un análisis factorial exploratorio (AFE) de las 48 variables a fin de descubrir dimensiones latentes que expliquen las relaciones entre las variables e identificar patrones subyacentes y reducir la dimensionalidad entre estas, facilitando así la interpretación de las relaciones entre las variables observadas. Los resultados indican que el modelo más adecuado se basa en la identificación de un pequeño número de factores que explican efectivamente la varianza en los datos.

2.10 Idoneidad de la realización del análisis factorial.

Como comenta Hernández-Suárez et al. (2024, p. 398), el índice Kaiser-Meyer-Olkin (KMO) y el test de esfericidad de Bartlett son indicadores preliminares para determinar la viabilidad de realizar un análisis factorial. El coeficiente KMO introducido por Kaiser (1974) expresa el sumatorio de correlaciones observadas al cuadrado, dividido por el sumatorio de las correlaciones observadas al cuadrado más el sumatorio de correlaciones parciales al cuadrado (Alaminos Chica et al., 2015, p. 118), como se observa en la siguiente expresión:

$$KMO = \frac{\sum_{i \neq j} \sum_{j \neq i} r_{ij}^2}{\sum_{i \neq j} r_{ij}^2 + \sum_{i \neq j} a_{ij}^2} \quad (5)$$

donde r_{ij} es el coeficiente de correlación simple entre las variables i y j , y a_{ij} es el coeficiente de correlación parcial entre las variables i y j .

Kaiser (1974, p. 35) sostiene que un coeficiente entre 0.90 y 1.0 sería excelente, de 0.80 hasta 0.89 puede considerarse meritorio, mientras que de 0.70 a 0.79 puede considerarse aceptable y de 0.60 a 0.69 malo, de 0.50 hasta 0.59 se considera insuficiente, y ya debajo de 0.49 es inaceptable. Valores bajos del coeficiente KMO indicarían que efectuar un análisis factorial no es viable, dado que la correlación entre pares de variables no puede ser bien explicada por las otras variables.

Aunado a la prueba KMO, la prueba de esfericidad de Bartlett (1950, p. 77) se utiliza para examinar la hipótesis nula de que las variables en el análisis están intercorrelacionadas en la población (Hernández-Suárez et al., 2024, p. 398). Alaminos Chica et al (2015, p. 118) señalan que con este test se comprueba la hipótesis nula que afirma que la matriz de correlación puede ser una matriz identidad. Si el parámetro Chi-cuadrado de la prueba de esfericidad es alto y la significancia asociada es baja, se rechaza la hipótesis de que la matriz de correlación es una matriz identidad. Por otro lado, si el parámetro Chi-cuadrado es excesivamente bajo, no es idóneo efectuar un análisis factorial de ese conjunto de variables.

Figura 4
Resultados de las pruebas KMO y Bartlett por el software SPSS 31.

Prueba de KMO y Bartlett		
Medida Kaiser-Meyer-Olkin de adecuación de muestreo		,944
Prueba de esfericidad de Bartlett	Aprox. Chi-cuadrado	17932,427
	gl	1128
	Sig.	<,001

La figura 4 muestra los resultados del software SPSS versión 31, resultando 0.944 para el KMO, denotando una excelente adecuación de los datos para un análisis factorial, y un *Chi-cuadrada* ≈ 17932.427 , con $p < 0.00$ para la significatividad del test de Esfericidad de Bartlett, aceptando H_0 , justificando la realización del análisis factorial.

2.11 Métodos de extracción.

Williams et al. (2010, p. 3) comentan que existen numerosas maneras de extraer factores: una es el análisis de componentes principales (ACP), otra la factorización de ejes principales (FAP), la de factorización de imagen, la de máxima verosimilitud, la factorización alfa y la factorización canónica. Sin embargo, el ACP y la FAP son los más utilizados en la literatura publicada. En la práctica, las diferencias entre ACP y la FAP suelen ser insignificantes, especialmente cuando las variables tienen una

alta fiabilidad o cuando hay 30 o más variables. ACP es el método predeterminado en muchos programas estadísticos y, además, se recomienda cuando no existe una teoría o modelo a priori.

Para la obtención de los factores en este análisis, se empleó el método de componentes principales, considerando que no existe un modelo previo y lo que se busca es contrastar las variables complejas emanadas del proceso de destilación de variables con los factores latentes que arroje el análisis factorial exploratorio. La figura 5 muestra los parámetros utilizados y el método de extracción de componentes principales (principal components).

2.11 Número de factores a extraer.

Para determinar el número de factores a extraer, Mavrou (2015, p.5) menciona que el número de variables que comprende cada factor idealmente es de 3 o 4, aunque incluso 2 variables podrían ser suficientemente mínimas para la extracción e interpretación de un factor determinado.


En la realización del análisis presentado, se consideró extraer 16 factores, tomando en cuenta las 48 variables del instrumento empleado, tomando en cuenta 3 variables por factor, de forma tal de cumplir con los criterios antes mencionados. En la figura 5 se observan los parámetros de extracción señalando la cantidad de factores.

2.12 Rotaciones.

Para mejorar el proceso de extracción de factores de forma tal que la solución obtenida no sea del todo satisfactoria debido a que la interpretación permanece confusa.

Figura 5

Captura de pantalla del software Statistica 12 con los parámetros de extracción.



En tal caso, se debe proceder con la rotación de los factores y, al hacerlo, transformar la matriz inicial en una que sea más fácil de interpretar (Roth, 2012, p.103). Existen dos técnicas de rotación comunes: la rotación ortogonal (varimax/quartimax) o la rotación oblicua (oblimin/promax). La rotación ortogonal varimax, desarrollada inicialmente por Thompson, es la técnica de rotación

más común en el análisis factorial, que produce estructuras factoriales no correlacionadas (Williams et al., 2010, p9). Este método minimiza el número de variables en un factor con cargas altas, lo que mejora la capacidad de interpretación de los factores. Este método considera que si se logra aumentar la varianza de las cargas factoriales al cuadrado de cada factor consiguiendo que algunas de sus cargas factoriales tiendan a acercarse a uno mientras que otras se acerquen a cero, lo que se obtiene es una pertenencia más clara e inteligible de cada variable a ese factor (Roth, 2012, p. 104).


Para la selección del método de rotación, Hair et al. (2004, p. 98) señalan que no existe una razón analítica para la elección de un método de rotación u otro y esta depende de las necesidades del investigador. Si se pretende reducir un gran número de variables originales, con independencia de la significancia resultante de los factores a un conjunto pequeño de variables correlacionadas para su uso posterior, la solución apropiada es ortogonal. En el análisis realizado, se empleó el método de rotación ortogonal Varimax Normalizado, como lo muestra la Figura 6.

2.13 Retención de factores.

El criterio de Kaiser trata de que se suprimen todos los factores con un autovalor (eigenvalor), es decir, la medida que representa la cantidad de varianza en las variables que el factor o componente es capaz de explicar, que es inferior a 1. Esto se debe a que es un sinsentido estadístico incluir un factor que explica menos que un indicador aislado. Partiendo de la varianza explicada, se han propuesto diferentes procedimientos para determinar el número de factores que deben ser empleados en un modelo. (Alaminos Chica et al., 2015, p.118).

Figura 6

Captura de pantalla del software Statistica 12 con los parámetros de rotación.



La Figura 7 muestra los autovalores calculados en el presente análisis, generados por el software Statistica 12, con los 8 factores.

Figura 7

Captura de pantalla de la tabla de 8 factores extraídos con sus Autovalores, generados por el software Statistica 12.

Eigenvalues (Respuestas de formulario 1 in A1.3b) Extraction: Principal components				
Value	Eigenvalue	% Total variance	Cumulative Eigenvalue	Cumulative %
1	19.48062	40.58463	19.48062	40.58463
2	4.60384	9.59134	24.08446	50.17596
3	3.49100	7.27291	27.57546	57.44888
4	2.68754	5.59904	30.26300	63.04791
5	1.98648	4.13850	32.24948	67.18641
6	1.67759	3.49497	33.92706	70.68139
7	1.20944	2.51967	35.13651	73.20105
8	1.06488	2.21850	36.20138	75.41955

Otro criterio adecuado para la determinación de los factores a considerar es el uso del diagrama de sedimentación. Este método fue propuesto por Cattell y la recomendación es mantener los factores cuyos coeficientes caen abruptamente y eliminar aquellos que permanecen en un nivel semejante (Alaminos Chica et al., 2015, p. 126). En ese sentido, Roth (2012, p. 93) señala que en dicha gráfica se observan los factores según su autovalor vistos en una línea que va descendiendo de derecha a izquierda. En el punto en que la línea deja de descender y toma una tendencia horizontal al eje de las x, se ubica el último factor que podría ser considerado para ser extraído.

La figura 8 muestra la gráfica de sedimentación correspondiente donde se aprecian los 19 factores graficados, se observa cómo se torna casi paralela al eje de las X en el factor 8, por lo que, para el análisis realizado, únicamente se explicarán los primeros cinco factores, considerando el criterio de sedimentación, además de que en dichos 5 factores se acumula el 49.54% del total de la varianza total.


2.14 La carga factorial.

Para la interpretación de las cargas factoriales, como lo señala Mavrou (2015, p. 7), Osborne y Costello (2004; Osborne & Costello, 2005) opinan que cargas de 0.50 pueden considerarse, por lo general, fuertes. Stevens (2002) y Field (2009) sostienen que para un nivel de significación $\alpha=0.01$ (bilateral) y $n=50$, cargas factoriales de 0.722 pueden considerarse significativas, mientras que para $n=100$ pueden ser suficientes cargas de aproximadamente 0.512. Hair et al. (2004) mencionan que para $n=70$ y $n=85$ las cargas factoriales deberían alcanzar el 0.65 y el 0.60 respectivamente. A su vez, es recomendable interpretar solo las cargas factoriales con un valor absoluto superior a 0.40, es decir, aquellas que aglutinan el 16% de la varianza de la variable (p645).

Para el presente análisis factorial exploratorio, se consideraron cargas factoriales de 0.7 y superiores, sin embargo, dependiendo de la interpretación del factor y de las variables involucradas, se consideraron para la interpretación cargas factoriales de 0.5 o incluso menores sin pasar al 0.4, esto con el fin de dar un sentido más amplio a la interpretación de la variable latente que involucra factores con variables medibles con cargas factoriales bajas.

Figura 8

Captura de pantalla de la gráfica de sedimentación de los factores con un autovalor superior a 1, extraídos por el software Statistica 12.



III. RESULTADOS Y DISCUSIÓN

Los resultados del análisis factorial se presentan en las siguientes tablas, con las cargas factoriales de las variables por cada uno de los 8 factores extraídos, así como su interpretación correspondiente.

Tabla 3

Factor 1. Apoyo de las aplicaciones y chatbots de IA en la solución de ejercicios y problemas de física.

Variable	Carga factorial
¿En qué medida utilizas un chatbot de inteligencia artificial como ChatGPT, Gemini, Copilot, Meta AI, etc., para ayudarte a resolver ejercicios y/o problemas de cálculo de voltajes, corrientes eléctricas, electromagnetismo y/o circuitos eléctricos (electricidad)?	0.8882
¿En qué medida utilizas un Chatbot de Inteligencia Artificial como ChatGTP, Gemini, Copilot, Meta AI, etc., para ayudarte a resolver ejercicios y/o problemas de cálculo de la presión de un fluido, teorema de Arquímedes, principio de Pascal, etc. (física)?	0.8844
¿En qué medida utilizas un chatbot de inteligencia artificial como ChatGPT, Gemini, Copilot, Meta AI, etc., para ayudarte a resolver ejercicios y/o problemas de reflexión y/o refracción de la luz (óptica)?	0.8660
¿En qué medida utilizas un chatbot de inteligencia artificial como ChatGPT, Gemini, Copilot, Meta AI, etc., para ayudarte a resolver ejercicios y/o problemas de cálculo de densidad de materiales, pesos específicos, etc. (física)?	0.8385
¿En qué medida utilizas un Chatbot de Inteligencia Artificial como ChatGTP, Gemini, Copilot, Meta AI, etc., para ayudarte a resolver ejercicios y/o problemas sobre química (balanceo de ecuaciones químicas, cálculos estequiométricos, etc.)?	0.8380
¿En qué medida utilizas un chatbot de inteligencia artificial como ChatGPT, Gemini, Copilot, Meta AI, etc., para ayudarte a resolver ejercicios y/o problemas de estática, cálculo de fuerzas, componentes rectangulares de fuerzas, momentos, etc. (física)?	0.7858
¿En qué medida utilizas un Chatbot de Inteligencia Artificial como ChatGTP, Gemini, Copilot, Meta AI, etc., para ayudarte a resolver ejercicios y/o problemas de cálculo de temperaturas y calor (termodinámica y/o transferencia de calor)?	0.7562

¿En qué medida utilizas un chatbot de inteligencia artificial como ChatGPT, Gemini, Copilot, Meta AI, etc., para ayudarte a resolver ejercicios y/o problemas de cálculo de velocidades, aceleraciones y dinámica (física)? 0.7375

La variable latente reflejada por el factor 1 que representa un eigenvalor de 19.48, reúne ítems mostrados en la Tabla 3 con cargas factoriales superiores a 0.7, denota una excelente asociación entre estas, relacionadas con la utilización de aplicaciones y chatbots de Inteligencia Artificial para auxiliarse en la solución de problemas de física, en lo que respecta a electricidad, electromagnetismo y/o circuitos eléctricos, hidrostática, hidrodinámica, óptica, propiedades de los materiales, química, estática, termodinámica, transferencia de calor y dinámica, lo que sugiere que el principal uso de los chatbots de inteligencia artificial como auxiliar en la solución de problemas es en las materias antes mencionadas.

Tabla 4

Factor 2. Percepción del concepto y del funcionamiento de las aplicaciones de Inteligencia Artificial.

Variable	Carga factorial
Percepción del funcionamiento de los Chatbots de Inteligencia Artificial.	0.8756
Percepción general de que es un Chatbot de Inteligencia Artificial.	0.8745
Percepción general del concepto de Inteligencia Artificial.	0.8642
Percepción de en qué dispositivos se utilizan Inteligencia Artificial.	0.8501

La Tabla 4 muestra el factor 2, el cual representa una variable latente con un autovalor de 4.603, aglutina reactivos con consistencia excelente, superior a 0.85, relacionados con la sensación que percibe el alumno de conocer de forma general qué es y cómo funciona un chatbot de inteligencia artificial, así como el concepto de qué es la inteligencia artificial y en qué dispositivos se emplea.

Tabla 5

Factor 3. Utilización de aplicaciones de Inteligencia Artificial para el aprendizaje de idiomas.

Variable	Carga factorial
Apoyo para el aprendizaje vocabulario de idiomas por medio de aplicaciones de Inteligencia Artificial.	0.8970
Apoyo en entrenamiento de pronunciación en conversaciones para el aprendizaje de idiomas por medio de aplicaciones de Inteligencia Artificial.	0.8906
Apoyo para el aprendizaje de la gramática de idiomas por medio de aplicaciones de Inteligencia Artificial.	0.8677
Apoyo en entrenamiento de escucha en conversaciones para aprendizaje de idiomas por medio de aplicaciones de Inteligencia Artificial.	0.8631

La muestra la variable latente reflejada por el factor 3 con un eigenvalor de 3.49 reúne ítems, mostrados en la Tabla 5 con cargas factoriales superiores a 0.85, que denota una excelente

asociación entre estas, relacionadas con el empleo por parte del alumno de chatbots de Inteligencia Artificial como ChatGTP, Gemini, Copilot, Claude u otras aplicaciones de aprendizaje de idiomas (ingles u otro) que incluyan IA, para el aprendizaje vocabulario de idiomas, el entrenamiento de la pronunciación en conversaciones, el aprendizaje de la gramática y el entrenamiento de escucha.

Tabla 6

Factor 4. Utilización de aplicaciones de Inteligencia Artificial en la búsqueda de información y redacción y textos.

Variable	Carga factorial
Apoyo en la realización de resúmenes de algún documento, artículo o libro por medio de aplicaciones de inteligencia artificial.	0.8422
Apoyo en la generación de ideas para la redacción por medio de aplicaciones de Inteligencia Artificial.	0.8011
Apoyo para elaborar ensayos o reportes, etc., por medio de aplicaciones de Inteligencia Artificial.	0.7994
Apoyo para parafrasear textos previamente escritos por medio de aplicaciones de Inteligencia Artificial.	0.7663
Apoyo para la búsqueda de información acerca de un tema en específico por medio de aplicaciones de Inteligencia Artificial.	0.7544

La variable latente reflejada por el factor 4 con un eigenvalor de 2.68 reúne ítems mostrados en la Tabla 6 con cargas factoriales superiores a 0.70, lo que indica una asociación sólida y consistente entre las variables que lo conforman. Dichas cargas sugieren que la variable latente está vinculada principalmente con la medida en que el alumno utiliza un Chatbot de Inteligencia Artificial como ChatGTP, Gemini, Copilot, Claude, etc., para realizar resúmenes de algún documento, artículo o libro, generar ideas para redacción de algún texto, redactar, ensayos, reportes, parafrasear textos previamente escritos es decir, reorganiza el texto manteniendo el mismo significado qué el de la oración original y buscar información acerca de un tema en específico.

Tabla 7

Factor 5. Utilización aplicaciones de Inteligencia Artificial en la creación de productos multimedia.

Variable	Carga factorial
Apoyo para la creación de videos y/o películas por medio de aplicaciones de Inteligencia Artificial.	0.7666
Apoyo para la creación de música por medio de aplicaciones de Inteligencia Artificial.	0.7483
Apoyo para la creación de personajes animados y/o avatares por medio de aplicaciones de Inteligencia Artificial.	0.7133
Apoyo genérico para la creación de imágenes por medio de aplicaciones de Inteligencia Artificial.	0.6727
Apoyo en el aprendizaje y/o en proyectos de desarrollo de redes sociales por medio de aplicaciones de Inteligencia Artificial.	0.5808
Apoyo para la creación infografías por medio de aplicaciones de Inteligencia Artificial.	0.5755

La variable latente reflejada por el factor 5 con un eigenvalor de 1.98, reúne ítems, mostrados en la tabla Tabla 7, con cargas factoriales de 0.55 a 0.77, indicando una asociación de aceptable a buena en variables relacionadas con el empleo de Chatbots de Inteligencia Artificial como ChatGTP, Gemini, Copilot, Claude, etc., para la creación de videos y/o películas, composición y producción de música, generación de personajes animados y/o avatares, imágenes, como apoyo para el desarrollo de contenidos para redes sociales y para la creación infografías, lo que denota el empleo de dichas aplicaciones para la generación de dichos productos.

Tabla 8

Factor 6. Utilización de aplicaciones de IA en enseñanza de matemáticas básicas.

Variable	Carga factorial
Apoyo en el aprendizaje y/o solución de ejercicios y problemas de fracciones y decimales por medio de aplicaciones de Inteligencia Artificial.	0.7329
Apoyo en el aprendizaje y/o solución de ejercicios y problemas de despeje de fórmulas por medio de aplicaciones de Inteligencia Artificial.	0.7302
Apoyo en el aprendizaje y/o solución de ejercicios y problemas de aritmética por medio de aplicaciones de Inteligencia Artificial.	0.6854
Apoyo en el aprendizaje y/o solución de ejercicios y problemas de factorizaciones, simplificaciones, etc., por medio de aplicaciones de Inteligencia Artificial.	0.6642
Apoyo en el aprendizaje y/o solución de ejercicios y problemas de geometría y trigonometría por medio de aplicaciones de Inteligencia Artificial.	0.6484
Apoyo en el aprendizaje y/o solución de ejercicios y problemas de enseñanza del cálculo diferencial y/o integral y/o vectorial y/o ecuaciones diferenciales por medio de aplicaciones de Inteligencia Artificial.	0.5565
Apoyo en el aprendizaje y/o solución de ejercicios y problemas de sistemas de ecuaciones lineales de dos o tres ecuaciones y variables por medio de aplicaciones de Inteligencia Artificial.	0.5303

La Tabla 8 muestra variable latente reflejada por el factor 6 con un eigenvalor de 1.677, reúne ítems con cargas factoriales de 0.5 a 0.75, indicando una asociación de aceptable a buena en variables relacionadas con el empleo de los Chatbot de Inteligencia Artificial como ChatGTP, Gemini, Copilot, Claude, etc., para ayudar a resolver ejercicios y/o problemas relacionados con aritmética, suma, resta, multiplicación y/o división con fracciones (quebrados) así como con cifras enteras, resolver ejercicios y/o problemas relacionados con despejes de fórmulas y/o ecuaciones, temas de álgebra como lo son operaciones con monomios, polinomios, cuadráticas, factorizaciones, simplificaciones, etc., geometría y trigonometría, cálculo diferencial y/o integral y/o vectorial y/o ecuaciones diferenciales y problemas de álgebra lineal como lo son sistemas de ecuaciones lineales de dos o tres variables por los métodos de

sustitución algebraica, Gauss, Gauss-Jordan, regla de Cramer u otro, lo que infiere el uso de herramientas de IA como auxiliar en la solución en dichas materias.

Tabla 9

Factor 7. Utilización de aplicaciones de Inteligencia Artificial en desarrollo de programas de computación.

Variable	Carga factorial
Apoyo en el aprendizaje y/o en proyectos de programación de computadoras por medio de aplicaciones de Inteligencia Artificial.	0.7483
Apoyo en el aprendizaje y/o en entendimiento de la sintaxis del lenguaje y la lógica de programación por medio de aplicaciones de Inteligencia Artificial.	0.7728
Apoyo en el aprendizaje y/o en buscar información acerca de comandos específicos de lenguajes de programación por medio de aplicaciones de Inteligencia Artificial.	0.7832

La Tabla 9 muestra los ítems del factor 7 con un eigenvalor de 1.209, el cual representa una variable latente con consistencia excelente, mostrando cargas factoriales superior a 0.70, relacionados con el uso de Chatbots de Inteligencia Artificial como ChatGTP, Gemini, Copilot, Claude, etc., como auxiliar en proyectos de programación de computadoras, en el entendimiento de la sintaxis del lenguaje y la lógica de los algoritmos para programación de computadoras y buscar información acerca de comandos específicos de lenguajes de programación (Basic, Pascal, C, C++, Java, Python, u otros), denotando en un alto uso de dichas aplicaciones en temas de programación de computadoras.

Tabla 10

Factor 8. Apoyo de las aplicaciones y chatbots de IA en traducción de documentos y presentaciones.

Variable	Carga factorial
Apoyo para la traducción de documentos Word o pdf por medio de aplicaciones de Inteligencia Artificial.	0.7853
Apoyo para la traducción de presentaciones en diapositivas por medio de aplicaciones de Inteligencia Artificial.	0.7719
Apoyo para la creación de líneas de tiempo por medio de aplicaciones de Inteligencia Artificial.	0.5324

El factor 8 tiene un eigenvalor de 1.0648, representa una variable latente que enmarca los reactivos mostrados en la Tabla 10 con consistencia excelente, superior a 0.75, relacionados con chatbot de Inteligencia Artificial como ChatGTP, Gemini, Copilot, Claude, etc., para traducir documentos Word o pdf de otro idioma al español y viceversa y para la traducir de otro idioma al español y viceversa y en menor medida para buscar fechas de acontecimientos y crear líneas de tiempo.

El análisis factorial realizado exhibe ocho variables latentes que abarcan el 75.41% de la varianza explicada, emanadas de los 48 ítems, altamente relacionadas, demuestran el uso de las aplicaciones y chatbots de IA en las asignaturas tales como la

física, los idiomas, la búsqueda de información, la redacción de textos, la creación de productos multimedia, las matemáticas básicas, el desarrollo de programas de computación y la traducción de documentos y presentaciones.

3.2 Discusión.

Los resultados del trabajo mostraron que el alumnado recurre a aplicaciones y chatbots de inteligencia artificial principalmente para apoyar la resolución de ejercicios y problemas de física, matemáticas y química. Este comportamiento coincide con los enfoques de Pappas y Drigas (2016) y Wang et al. (2023), que señalan que los asistentes de IA promueven un aprendizaje interactivo y adaptativo en matemáticas al ofrecer soluciones innovadoras a problemas complejos y mejoran el aprendizaje.

A su vez, en la investigación los participantes reportaron utilizar la IA como herramienta auxiliar para aprender idiomas, buscar información y redactar textos. Este hallazgo coincide con los estudios de Kim (2021), citados en O'Dea (2023), en lo referente a que los chatbots de aprendizaje de idiomas proporcionan experiencias individualizadas y prácticas simuladas que mejoran la fluidez y la confianza de los alumnos, con evidencia empírica de mejores resultados en competencias orales.

Además, coincide con Morantes (2023) respecto al uso de la IA para la investigación científica y búsqueda de información académica.

Por otro lado, los resultados evidenciaron que los estudiantes emplean la IA en menor medida para crear productos multimedia, desarrollar programas y traducir documentos, lo cual coincide con Anantrasirichai y Bull (2020), quienes describen cómo la IA potencia la narrativa, el periodismo y la música. Por otro lado, coincide con Terán (2023) en que la IA favorece la enseñanza de programación al proporcionar sugerencias de código y retroalimentación en tiempo real. Sin embargo, el uso reducido observado en este estudio sobre estas aplicaciones sugiere una diferencia entre el potencial teórico y la práctica estudiantil, aunque las posibilidades son amplias, los alumnos aún no aprovechan plenamente estas herramientas, lo cual aporta una nueva perspectiva sobre la adopción de la IA en tareas creativas y de programación básicas.

Finalmente, los hallazgos aportan nueva evidencia al destacar que, aunque los estudiantes emplean la IA regularmente, existe una brecha de comprensión que puede limitar el aprovechamiento de estas herramientas y que no se observa en los estudios revisados, evidenciando una discrepancia entre la percepción que los estudiantes entienden sobre qué es la IA y la forma en que la utiliza, lo que no coincide con las revisiones de Crompton y Song (2021), que dan énfasis al protagonismo de la IA en educación superior y en las oportunidades que brinda para la tutoría adaptativa.

IV. CONCLUSIONES

Para esta investigación con enfoque cuantitativo, los hallazgos permiten afirmar que el uso académico de las

aplicaciones y chatbots de inteligencia artificial por parte de los alumnos se da, en primera instancia, en asignaturas de carácter científico-técnico, como apoyo en la solución de ejercicios y problemas de física, matemáticas, química, etc. A su vez, se evidencia que existe una clara percepción conceptual sobre qué es y cómo se utiliza la IA, además, se observa su uso como auxiliar en el aprendizaje de idiomas, la búsqueda de información y la redacción de textos, y en menor medida, en la creación de productos multimedia, la resolución de matemáticas básicas, el desarrollo de programas de computación y la traducción de documentos y presentaciones.

Con esto se puede afirmar que los estudiantes recurren a estas aplicaciones de forma transversal, como soporte a su aprendizaje, así como auxiliares en sus actividades instrumentales y de producción académica. Finalmente se concluye que el uso de los chatbots y aplicaciones de inteligencia artificial permitirá desarrollar nuevos ambientes de aprendizaje que permitan potencializar el aprendizaje de los estudiantes y exponenciar la calidad y de los productos académicos que estos desarrollan. Complejidad.

V. AGRADECIMIENTOS

En primera instancia, agradezco a las autoridades de la Universidad Politécnica de Gómez Palacio, al Mtro. Carlos Gerardo Landeros Araujo, Rector de la Universidad, al Lic. Luis Antonio Gutiérrez Benítez, Secretario Académico, y a la Dra. Grace Lizbeth Quintana Juárez, Jefa del Departamento de Idiomas y Educación Continua, por las facilidades mostradas para la aplicación de la totalidad de los instrumentos de evaluación utilizados para la presente investigación. En segundo lugar, agradecer a las autoridades del Instituto Tecnológico Superior de Lerdo, al Dr. José Dimas López Martínez y al Dr. José Alejandro Valdez Nieblas, Encargado de la Dirección Académica, por la oportunidad brindada para realizar la presente investigación. En tercera instancia, agradezco al Dr. Aurelio García Alonso, Coordinador de Posgrado de la Universidad Autónoma de la Laguna, por el soporte técnico e institucional brindado para la realización de la presente investigación. Por último, agradezco al Dr. Felipe del Río Olague, docente del Doctorado en Desarrollo Educativo de la Universidad Autónoma de la Laguna, por su invaluable guía y consejo para la realización de la presente investigación.

VI. REFERENCIAS

- Giraldo, C. A. S. (2023). INNOVACIÓN EN LA EDUCACIÓN A TRAVÉS DE LA IA INNOVATION IN EDUCATION THROUGH THE IA. *Revista de Investigación Científica, Empresarial y Tecnológica-RICET*, 8(3).
- Crompton, H., & Song, D. (2021). The Potential of Artificial Intelligence in Higher Education. <https://doi.org/10.35575/RVUCN.N62A1>
- Pappas, M. A., & Drigas, A. (2016). Incorporation of Artificial Intelligence Tutoring Techniques in Mathematics. *International Journal of*

- Engineering Pedagogy (IJEP).
<https://doi.org/10.3991/IJEP.V6I4.6063>
- Wang, T., Lund, B. D., Marengo, A., Pagano, A., Teel, Z. (Abbie), & Pange, J. (2023). Exploring the Potential Impact of Artificial Intelligence (AI) on International Students in Higher Education: Generative AI, Chatbots, Analytics, and International Student Success. *Applied Sciences*. <https://doi.org/10.3390/app13116716>
- Terán, H. (2023). Encuentro Internacional de Educación en Ingeniería ACOFI 2023. La Implementación de La Inteligencia Artificial En La Enseñanza de La Programación. Un Estudio Sobre El Uso Ético de ChatGPT En El Aula, 11.
<https://doi.org/https://doi.org/10.26507/paper.2768>
- Portella-Cleves, J.-E., & Rodríguez-Hernández, A.-A. (2023). Enhancing Programming Education with an Active Learning Plan and Artificial Intelligence Integration. *Revista Facultad de Ingeniería*, 33(67), 33(67).
<https://doi.org/https://doi.org/10.19053/01211129.v33.n67.2024.16328>
- Morantes, I. C. (2023). Inteligencia artificial (IA) en la investigación científica: Sistematización y reflexiones sobre experiencias educativas. *Educare*.
<https://doi.org/https://doi.org/10.46498/reduipb.v27i3.2050>
- Anantrasirichai, N., & Bull, D. (2020). Artificial Intelligence in the Creative Industries: A Review. *arXiv: Computer Vision and Pattern Recognition*. <https://doi.org/10.1007/S10462-021-10039-7>
- O'Dea, X. (2023). Is Artificial Intelligence Really the Next Big Thing in Learning and Teaching in Higher Education? A Conceptual Paper. *Journal of University Teaching and Learning Practice*.
<https://doi.org/10.53761/1.20.5.05>
- Krejcie, R. V., & Morgan, D. W. (1970). Determining Sample Size for Research Activities. *Educational and Psychological Measurement*, 30(3), 607-610. <https://doi.org/10.1177/001316447003000308> (Original work published 1970).
- Hernández, D., Fernández, C., & Baptista, M. D. P. (2014). *Metodología de la investigación* 6ta Edición Sampieri.
- Zeynivandnezhad, F., Rashed, F., & Kanooni, A. (2019). Exploratory factor analysis for TPACK among mathematics teachers: Why, what and how. *Anatolian journal of education*, 4(1), 59-76.
- Williams, B., Onsman, A., & Brown, T. (2010). Exploratory factor analysis: A five-step guide for novices. *Australasian journal of paramedicine*, 8, 1-13.
- González, C. G., Lise, A. V., & Felpeto, A. B. (2013). *Tratamiento de datos con R, Estadística y SPSS*. Ediciones Díaz de Santos.
- Hernández-Suarez, C. A., Fernández-César, R., & Ramírez-Leal, P. (2024). Exploración de creencias sobre el aprendizaje de las matemáticas: Un estudio de habilidad y análisis factorial con estudiantes de educación básica y media. *Saber, ciencia y libertad*, 19(1), 391-418.
- Alaminos Chica, A., Francés García, F. J., Penalva Verdú, C., & Santacreu Fernández, Ó. A. (2015). Análisis multivariante para las Ciencias Sociales I. Índices de distancia, conglomerados y análisis factorial.
- Kaiser, H. F. (1974). An index of factorial simplicity. *psychometrika*, 39(1), 31-36.
- Bartlett, M. S. (1950). Tests of significance in factor analysis. *British Journal of Psychology*, 3, 77-85.
- Roth, E. (2012). Análisis multivariado en la investigación psicológica: Modelado predictivo y causal con SPSS y AMOS.
- Hair, J. F., Anderson, R. E., Tatham, R. L., & Black, W. C. (2004). *Análisis multivariante*.
- Mavrou, I. (2015). Análisis factorial exploratorio: cuestiones conceptuales y metodológicas. *Revista Nebrija de Lingüística Aplicada a la enseñanza de lenguas*, (19), 71-80.

No.	Rol	Descripción
		<i>Nota 1: favor de eliminar los corchetes una vez colocado su nombre</i> <i>Nota 2: elimine el todo texto de apoyo que se proporcionó en los asteriscos de cada fila y debajo de cada nombre.</i>
1	Conceptualización [Conceptualization]	[Carlos Eduardo Martos Martínez] <i>* Definición: Ideas; formulación o desarrollo de los objetivos y metas generales de la investigación.</i>
2	Curación de datos [Data curation]	[Carlos Eduardo Martos Martínez] <i>* Definición: Actividades de gestión para anotar (generar metadatos), depurar datos y mantener los datos de investigación (incluido el código de software, cuando sea necesario para interpretar los datos propiamente dichos) con vistas a su uso inicial y su reutilización posterior.</i>
3	Análisis formal [Formal analysis]	[Carlos Eduardo Martos Martínez] <i>* Definición: Aplicación de técnicas estadísticas, matemáticas, computacionales u otras técnicas formales para analizar o sintetizar los datos del estudio.</i>
4	Obtención de fondos [Funding acquisition]	[Carlos Eduardo Martos Martínez] <i>* Definición: Obtención del apoyo financiero para el proyecto que ha dado lugar a esta publicación.</i>
5	Investigación [Investigation]	[Carlos Eduardo Martos Martínez] <i>* Definición: Llevar a cabo un proceso de investigación, concretamente la realización de experimentos o la recopilación de datos o pruebas.</i>
6	Metodología [Methodology]	[Carlos Eduardo Martos Martínez] <i>* Definición: Desarrollo o diseño de la metodología; creación de modelos.</i>
7	Administración del proyecto [Project administration]	[Carlos Eduardo Martos Martínez] <i>* Definición: Responsabilidad de gestión y coordinación de la planificación y ejecución de la actividad de investigación.</i>
8	Recursos [Resources]	[Carlos Eduardo Martos Martínez] <i>* Definición: Suministro de materiales de estudio, reactivos, materiales, pacientes, muestras de laboratorio, animales, instrumentación, recursos informáticos u otras herramientas de análisis.</i>
9	Software [Software]	[Carlos Eduardo Martos Martínez] <i>* Definición: Programación, desarrollo de software; diseño de programas informáticos; implementación del código informático y los algoritmos de apoyo; pruebas de los componentes de código existentes.</i>
10	Supervisión [Supervision]	[Carlos Eduardo Martos Martínez] <i>* Definición: Responsabilidad de supervisión y liderazgo en la planificación y ejecución de la actividad de investigación, incluida la tutoría externa al equipo principal.</i>
11	Validación [Validation]	[Carlos Eduardo Martos Martínez] <i>* Definición: Verificación, ya sea como parte de la actividad o por separado, de la replicabilidad/reproducibilidad general de los resultados/experimentos y otros productos de la investigación.</i>
12	Visualización [Visualization]	[Carlos Eduardo Martos Martínez] <i>* Definición: Preparación, creación y/o presentación del trabajo publicado, concretamente la visualización o presentación de datos.</i>
13	Redacción - borrador original [Writing – original draft]	[Carlos Eduardo Martos Martínez] <i>* Definición: Preparación, creación y/o presentación del trabajo publicado, concretamente la redacción del borrador inicial (incluida la traducción de fondo).</i>
14	Redacción - revisión y edición [Writing – review & editing]	[Carlos Eduardo Martos Martínez] <i>* Definición: Preparación, creación y/o presentación del trabajo publicado por parte de miembros del grupo de investigación original, específicamente revisión crítica, comentarios o revisión, incluyendo las etapas previas o posteriores a la publicación.</i>