

## La dependencia de la inteligencia artificial como predictor de la autoeficacia académica en estudiantes de ingeniería de una universidad pública peruana

Artificial intelligence dependency as a predictor of academic self-efficacy among engineering students at a peruvian public university

 Ana Maria Reyna Segura<sup>1</sup>

 Andres Murrieta Davila<sup>2</sup>

 Victor Luis Araujo Arancibia<sup>3</sup>

 Eddy Hugo Arias Borda<sup>4</sup>

 Medalit Nieves Salcedo Rodriguez<sup>5</sup>

 Katia Vigo Ingar<sup>6</sup>

### Resumen

**Introducción:** La integración de la inteligencia artificial en la educación superior ha transformado los procesos de aprendizaje, generando preocupaciones sobre sus posibles efectos en la autonomía y el desempeño de los estudiantes. **Objetivo:** Determinar la capacidad predictiva de la dependencia de la inteligencia artificial sobre la autoeficacia académica en estudiantes de ingeniería de una universidad peruana. **Metodología:** Se realizó un estudio cuantitativo con diseño predictivo transversal. La muestra estuvo conformada por 134 estudiantes de dos facultades de ingeniería de una universidad pública. Se aplicaron la Escala de Dependencia a la Inteligencia Artificial y un instrumento de Autoeficacia Académica, ambos con adecuados niveles de validez y confiabilidad. **Resultados:** La dependencia de la inteligencia artificial predice de manera significativa la autoeficacia académica con un efecto negativo moderado ( $\beta = -0.457$ ;  $p < .001$ ). El modelo explicó el 20.9 % de la varianza de la autoeficacia ( $R^2 = 0.209$ ), evidenciando que un mayor nivel de dependencia se asocia con menor percepción de autoeficacia académica. **Conclusiones:** La dependencia de la inteligencia artificial es un predictor significativo y negativo de la autoeficacia académica en estudiantes de ingeniería. Estos hallazgos sugieren la necesidad de promover estrategias pedagógicas que fortalezcan la autonomía, el pensamiento crítico y la confianza en las propias capacidades en contextos educativos mediados por IA.

**Palabras clave:** Dependencia de la inteligencia artificial; Autoeficacia académica; Inteligencia artificial generativa; Estudiantes de ingeniería; Educación superior

### Abstract

**Introduction:** The integration of artificial intelligence (AI) into higher education has transformed learning processes, raising concerns regarding its potential effects on student autonomy and performance. **Objective:** To determine the predictive power of artificial intelligence dependency on academic self-efficacy among engineering students at a Peruvian public university. **Methodology:** A quantitative study was conducted using a cross-sectional predictive design. The sample consisted of 134 students from two engineering faculties at a public university. The Artificial Intelligence Dependency Scale and an Academic Self-Efficacy instrument were administered, both of which demonstrated adequate levels of validity and reliability. **Results:** Artificial intelligence dependency significantly predicts academic self-efficacy with a moderate

<sup>1-6</sup> Universidad Nacional del Callao, Callao, Perú, <sup>2-3</sup> Universidad Nacional de la Amazonía Peruana, Iquitos, Perú, <sup>4</sup> Universidad Nacional Mayor de San Marcos, Lima, Perú, <sup>5</sup> Universidad Católica Sedes Sapientiae, Lima, Perú

Artículo recibido 11 de marzo 2026 | Aceptado 13 de mayo 2026 | Publicado 1 de julio 2026

**Autor de correspondencia:** [amreynas@unac.edu.pe](mailto:amreynas@unac.edu.pe)

**Conflicto de interés:** Los autores declaran no tener conflicto de intereses.

**Como citar:** Reyna Segura, A. M., Murrieta Davila, A., Araujo Arancibia, V. L., Arias Borda, E. H., Salcedo Rodriguez, M. N., & Vigo Ingar, K. (2026). La dependencia de la inteligencia artificial como predictor de la autoeficacia académica en estudiantes de ingeniería de una universidad pública peruana. *Tribunal. Revista en Ciencias de la Educación y Ciencias Jurídicas*, 6(16), 1-14.

<http://doi.org/10.59659/revistatribunal.v6i16.462>

negative effect ( $\beta = -.457$ ;  $p < .001$ ). The model accounted for 20.9% of the variance in self-efficacy ( $R^2 = .209$ ), indicating that higher levels of dependency are associated with lower perceived academic self-efficacy. **Conclusions:** Artificial intelligence dependency is a significant negative predictor of academic self-efficacy in engineering students. These findings suggest the need to foster pedagogical strategies that strengthen autonomy, critical thinking, and confidence in individual capabilities within AI-mediated educational environments.

**Keywords:** Artificial intelligence dependency; Academic self-efficacy; Generative artificial intelligence; Engineering students; Higher education

## Introducción

En la actualidad, la expansión de la inteligencia artificial generativa en la educación superior ha modificado las dinámicas de aprendizaje y producción académica en estudiantes universitarios en el mundo. Diversos estudios señalan que herramientas como ChatGPT y otros tipos de sistemas basados en GenAI (IA generativa) se han integrado en tareas de redacción, resolución de problemas y apoyo conceptual dentro del aula universitaria (Deng et al., 2025). Esta incorporación se está extendiendo y es parte del estudio diario, especialmente en situaciones donde la carga académica requiere respuestas rápidas y organizadas (Ateeq et al., 2024; Sri Tulasi y Inayath Ahamed, 2024). Investigaciones recientes señalan que la IA permite obtener retroalimentación instantánea y mejorar los procesos de búsqueda de información, lo que influye en la eficiencia académica (Singh y Hiran, 2022). Sin embargo, la incorporación de la IA necesita un análisis reflexivo de sus implicaciones pedagógicas y formativas (Samala et al., 2025; Cui y Alias, 2024).

La literatura actual también reconoce que la sobreutilización de la IA no está exenta de riesgos en la educación (Karamuk, 2025; Tian y Zhang, 2025). En concreto, se ha hallado que una mayor dependencia de instrumentos de IA se relaciona con una reducción del pensamiento crítico y una mayor fatiga cognitiva en estudiantes universitarios (Tian y Zhang, 2025). Otros estudios indican que el uso problemático de GenAI disminuye el pensamiento autónomo y favorece la externalización regular de procesos analíticos que antes requerían elaboración propia (Zhang et al., 2024; Huang y Wu, 2025). Estos resultados sugieren que el acceso constante a respuestas automatizadas va transformando la manera en que el estudiante aborda tareas académicas complejas.

Aquí es donde se manifiesta la dependencia de la IA, un patrón de uso en el que se siente la necesidad de usarla, se busca ayuda automatizada y se experimenta incomodidad cuando no se dispone de esta tecnología. Se concibe este tipo de dependencia como un constructo psicológico asociado a sentimientos de vulnerabilidad, necesidad de validación externa y temor a la obsolescencia personal frente a sistemas inteligentes (Morales-García et al., 2024). Además, estudios recientes muestran que los individuos tienden a sobreconfiar en recomendaciones generadas por IA, incluso cuando disponen de información propia suficiente para decidir (Klingbeil et al., 2024). De modo que este tipo de dependencia se orienta al vínculo que afecta la manera en que un estudiante regula su comportamiento académico y evalúa sus capacidades.

Investigaciones actuales muestran que estudiantes con mayor dependencia de GenAI reportan niveles más bajos de pensamiento independiente y una tendencia a sobreestimar

sus resultados cuando reciben apoyo constante de sistemas automatizados (Huang y Wu, 2025; Jia et al., 2025). Este patrón sugiere que la asistencia continua puede modificar la forma en que el estudiante interpreta sus logros académicos. Cuando el rendimiento se alcanza mediante intervención tecnológica frecuente, la atribución del éxito puede modificarse del esfuerzo personal hacia el recurso digital. Además, una exposición prolongada a respuestas generadas por IA afecta en la toma de decisiones académicas y en la confianza depositada en soluciones externas (Klingbeil et al., 2024).

En este contexto, la autoeficacia se refiere a las creencias que el individuo mantiene sobre su capacidad para organizar y ejecutar acciones orientadas al logro de metas específicas. (Bandura, 1997) Esta variable es clave para la comprensión del comportamiento del estudiante frente a las demandas universitarias. En ese sentido, la investigación educativa ha demostrado que niveles altos de autoeficacia se asocian con mayor persistencia ante tareas difíciles, mejor autorregulación y mayor rendimiento académico (Adams et al., 2020; Afari y Ahmed, 2022).

Además, se ha señalado que la autoeficacia afecta la manera en que el estudiante afronta situaciones académicas estresantes y valora su propio desempeño (Schunk y DiBenedetto, 2020). Por lo tanto, todo aquello que la altere, cambiará la forma en que el estudiante perciba su propia capacidad académica.

La dependencia de la IA y la autoeficacia académica se vuelven importantes en el momento en que las creencias de competencia se van desarrollando a medida de experiencias directas resolviendo tareas. Si el estudiante constantemente deja en manos de sistemas automatizados el análisis y la resolución de problemas, las posibilidades de consolidar experiencias propias de dominio se reducen. Investigaciones actuales indican que la dependencia en la IA se relaciona con una disminución del pensamiento autónomo y una alteración en la manera en que los estudiantes evalúan su desempeño académico (Huang y Wu, 2025; Jia et al., 2025). Además, la sobreconfianza en las sugerencias de la IA puede sesgar la propia valoración de los resultados académicos (Klingbeil et al., 2024). Esta situación abre la interrogante de si la dependencia psicológica a instrumentos de IA influye en la percepción de un estudiante para afrontar retos académicos.

Aunque la investigación sobre el uso educativo de la IA y sus efectos cognitivos va en aumento, todavía hay poca evidencia empírica que examine directamente cómo afecta a la autoeficacia académica. La mayoría de las investigaciones se ha centrado en el pensamiento crítico, la fatiga cognitiva o el rendimiento general, pero no en la evaluación de las creencias de competencia relacionadas con el uso prolongado de la IA (Tian y Zhang, 2025; Zhang et al., 2024). Además, aunque existen herramientas para medir la dependencia de la IA en estudiantes universitarios, su asociación directa con la percepción de capacidad académica no ha sido explorada en detalle (Morales-García et al., 2024). Esta falta de evidencia concreta es significativa en campos como la ingeniería, donde el aprendizaje se basa en la resolución independiente de problemas y el análisis técnico.

Este escenario evidencia un vacío de conocimiento respecto a la dependencia de la IA, debido a la escasa evidencia cuantitativa que evalúe su capacidad predictiva sobre variables como la autoeficacia académica. En particular, no se ha examinado mediante modelos de regresión si la dependencia de la IA explica de manera significativa la

variabilidad en las creencias de competencia académica en estudiantes de ingeniería. Por ello, el presente estudio tiene como objetivo determinar la capacidad predictiva de la dependencia de la inteligencia artificial sobre la autoeficacia académica en estudiantes de ingeniería de una universidad peruana. Con este análisis se busca proporcionar evidencia empírica que permita comprender los efectos de la dependencia a la IA y orientar decisiones pedagógicas que fortalezcan la autonomía, la autorregulación y la percepción de capacidad personal en contextos universitarios donde la tecnología forma parte del proceso formativo.

## Método

La investigación se abordó desde un enfoque cuantitativo, basándose en la recolección sistemática de datos y su análisis estadístico para probar las hipótesis y responder a los objetivos planteados. Se utilizó un diseño no experimental, ya que las variables se estudiaron en su ambiente natural, sin manipulación ni control directo por el investigador. Además, el estudio se ajustó a la estrategia asociativa y a un diseño predictivo transversal (DPT), según la clasificación de [Ato et al. \(2013\)](#). Este tipo de diseño recurre a modelos de regresión para estimar el comportamiento de una variable criterio a partir de una o más variables predictoras, permitiendo establecer capacidad de predicción estadística sin atribuir relaciones de causalidad directa ([Ato et al., 2013](#)). En consecuencia, el enfoque supera la mera identificación de asociaciones, al cuantificar la proporción de varianza explicada por los predictores en el fenómeno analizado.

La población del estudio estuvo conformada por los estudiantes matriculados en el periodo académico 2025, en la Universidad Nacional José Faustino Sánchez Carrión (UNJFSC), específicamente en la Facultad de Ingeniería Agraria, Industrias Alimentarias y Ambiental, así como en la Facultad de Ingeniería Química y Metalúrgica. Estas unidades académicas concentran programas vinculados a formación científico-tecnológica con alta demanda de resolución de problemas y uso de herramientas digitales en contextos formativos. En este marco, la muestra estuvo integrada por 134 estudiantes seleccionados mediante un muestreo no probabilístico por conveniencia, considerando criterios de accesibilidad y disposición voluntaria para participar en la investigación. Dado el carácter no probabilístico del procedimiento, los resultados deben interpretarse con cautela en términos de generalización poblacional, limitándose estrictamente al grupo estudiado.

Se empleó la Escala de Dependencia a la Inteligencia Artificial (DAI), la cual es un instrumento diseñado para evaluar el grado de vinculación problemática, uso excesivo y necesidad percibida de herramientas de inteligencia artificial generativa en contextos académicos. El cuestionario está conformado por 5 ítems estructurados en formato Likert de cinco alternativas de respuesta, desde “Totalmente falso para mí” hasta “Me describe perfectamente”. De este modo, se puede estimar el nivel de dependencia en función de la frecuencia o intensidad del comportamiento reportado ([Morales-García et al., 2024](#)). Posteriormente, se llevó a cabo una prueba piloto dirigida a 40 estudiantes. Para el presente estudio, la confiabilidad del cuestionario se calculó mediante el coeficiente omega de McDonald, obteniéndose un valor de  $\omega = 0.937$ , lo que indica un nivel de confiabilidad excelente y respalda la precisión de las puntuaciones obtenidas en la muestra analizada. Además, el cuestionario fue validado por 3 jueces expertos.

Por otra parte, se utilizó la Escala de Autoeficacia Académica (ACAES), desarrollada y validada por [Galleguillos-Herrera y Olmedo-Moreno \(2019\)](#), instrumento compuesto por 18 ítems distribuidos en tres dimensiones: Confianza en el desempeño de la tarea, esfuerzo en la realización de la tarea y comprensión de la tarea, tal como se reporta en la validación original. Las afirmaciones se responden mediante una escala tipo Likert de cinco categorías, desde “Nunca puedo” hasta “Siempre puedo”. Para el presente estudio se realizó una validación de contenido mediante juicio de tres expertos, quienes evaluaron y verificaron la claridad, pertinencia y coherencia semántica de los ítems. Posteriormente, se efectuó una prueba piloto en 40 estudiantes de ingeniería y se estimó la consistencia interna mediante el coeficiente omega de McDonald, obteniéndose un valor de  $\omega = 0.837$ , lo que indica la adecuada confiabilidad para su aplicación en esta muestra universitaria.

### **Procesamiento de los datos**

Antes de la recolección de información, se gestionó la autorización formal de las autoridades de las facultades. Posteriormente, los estudiantes fueron informados sobre los objetivos del estudio, el carácter académico de la investigación, la confidencialidad de sus respuestas y su derecho a retirarse en cualquier momento sin consecuencias. La participación fue voluntaria y anónima, previa aceptación del consentimiento informado. Los cuestionarios se aplicaron de manera colectiva en formato presencial y las respuestas fueron exportadas a una base de datos en Excel para su depuración. En este proceso, se verificó la integridad de los registros, se codificaron las variables y se construyeron los puntajes totales conforme a los criterios establecidos. La base consolidada fue procesada mediante software estadístico RStudio para su análisis descriptivo e inferencial.

### **Análisis de datos**

En una primera etapa se llevó a cabo el análisis descriptivo de las variables sociodemográficas y de los niveles de dependencia a la IA y autoeficacia académica, empleando frecuencias y porcentajes. Para la categorización descriptiva se aplicó una baremación basada en el rango de puntaje de cada escala, dividiendo la amplitud total en tres intervalos equivalentes: bajo, moderado y alto. Esta clasificación se utilizó exclusivamente con fines descriptivos, mientras que para los análisis inferenciales se trabajó con los puntajes continuos.

De forma seguida, en la fase inferencial, se estimó un modelo de regresión lineal simple para evaluar la capacidad predictiva de la dependencia de la IA sobre la autoeficacia académica, conforme al diseño predictivo transversal adoptado. Para ello, se evaluaron los supuestos del modelo mediante el examen de la linealidad a través de gráficos de dispersión, la revisión de la normalidad y homogeneidad de varianzas mediante el análisis de residuos estandarizados, la comprobación de la independencia de errores con el estadístico Durbin-Watson y la identificación de observaciones potencialmente influyentes mediante la distancia de Cook y la distancia de Mahalanobis. El desempeño del modelo se reportó mediante los coeficientes  $R$ ,  $R^2$  y  $R^2$  ajustado, el estadístico  $F$  del contraste global y los parámetros  $B$  y  $\beta$  con sus respectivos errores estándar e intervalos de confianza al 95 %. Ante la presencia de indicios de heterocedasticidad, se calcularon errores estándar robustos tipo HC3 con el fin de verificar la estabilidad inferencial de los coeficientes estimados. En todas las pruebas se estableció un nivel de significancia de  $p < .05$ .

## Resultados

La Tabla 1 presenta las características sociodemográficas de los 134 estudiantes de ingeniería de la Facultad de Ingeniería Agraria, Industrias Alimentarias y Ambiental y de la Facultad de Ingeniería Química y Metalúrgica de la Universidad Nacional José Faustino Sánchez Carrión, Huacho. El 53.0 por ciento corresponde a hombres y el 47.0 por ciento a mujeres, lo que muestra una distribución equilibrada por sexo. En cuanto a la situación laboral, el 67.9 por ciento indicó no trabajar, mientras que el 32.1 por ciento señaló que mantiene una actividad laboral paralela a sus estudios. Estos datos permiten contextualizar los análisis posteriores, ya que una proporción relevante del grupo combina formación académica con empleo, lo que podría incidir en sus dinámicas de estudio y en las variables evaluadas.

**Tabla 1.** Características sociodemográficas

Variable	Categoría	n	%
Sexo	Hombre	71	53
	Mujer	63	47
Situación laboral	Sin trabajo	91	67.9
	Trabaja	43	32.1

Según la Tabla 2, se muestra la distribución de los niveles en la dependencia de la IA, la autoeficacia académica y sus dimensiones en los estudiantes de ingeniería evaluados. En la dependencia de la IA, predomina el nivel moderado con un 59.7 %, mientras que el nivel alto alcanza un 20.9 % y el nivel bajo un 19.4 %. En la autoeficacia académica se observa mayor concentración en el nivel alto con un 45.5 %, seguido del nivel moderado con un 35.1 % y el nivel bajo con un 19.4 %. En las dimensiones, el esfuerzo en realizar la tarea presenta el mayor porcentaje en nivel alto con el 53.0 %, lo que indica una percepción elevada de dedicación académica en más de la mitad del grupo. La confianza en el desempeño se distribuye principalmente en el nivel moderado con un 41.8 %, y la comprensión de la tarea se concentra en el nivel moderado con el 61.2 %. Estos resultados describen un perfil donde predomina una autoeficacia percibida alta o moderada, en contraste con una dependencia a la IA mayoritariamente moderada dentro de la muestra analizada.

**Tabla 2.** Niveles de dependencia de la IA, autoeficacia académica y sus dimensiones

VARIABLES/dimensiones	Alto n (%)	Moderado n (%)	Bajo n (%)
VI. Dependencia de la IA	28 (20.9)	80 (59.7)	26 (19.4)
VD. Autoeficacia académica	61 (45.5)	47 (35.1)	26 (19.4)
D1. Confianza en el desempeño de la tarea	52 (38.8)	56 (41.8)	26 (19.4)
D2. Esfuerzo en realizar la tarea	71 (53.0)	38 (28.4)	25 (18.7)
D3. Comprensión de la tarea	27 (20.1)	82 (61.2)	25 (18.7)

De acuerdo a la Tabla 3, se presenta el resumen del modelo de regresión lineal simple. El coeficiente de correlación indica una asociación moderada entre la dependencia de la IA y la autoeficacia académica,  $R = 0.457$ . El modelo explica el 20.9 % de la variabilidad de la autoeficacia académica,  $R^2 = 0.209$ , mientras que el  $R^2$  ajustado de 0.203 muestra que el ajuste se mantiene estable al considerar el tamaño muestral y el número de predictores.

El nivel de significancia global del modelo fue  $p < .001$ , lo que confirma que la relación observada no se debe al azar. El error estándar de la estimación fue 12.858, lo que refleja la desviación promedio entre los valores observados y los valores estimados por el modelo. El estadístico Durbin-Watson fue 1.385, valor que indica independencia aceptable de los errores. En conjunto, estos resultados evidencian que el modelo presenta un ajuste adecuado y capacidad predictiva significativa en la muestra analizada.

**Tabla 3.** Resumen del modelo de regresión lineal

R	R <sup>2</sup>	R <sup>2</sup> ajustado	p	Error estándar	Durbin-Watson
0.457	0.209	0.203	< .001	12.858	1.385

Con base en la Tabla 4, se presenta el análisis de varianza del modelo de regresión. El contraste global fue estadísticamente significativo,  $F(1, 132) = 34.834$ ,  $p < .001$ , lo que indica que el modelo explica una proporción significativa de la variabilidad en la autoeficacia académica. Este resultado confirma que la dependencia de la IA aporta capacidad predictiva significativa dentro de la muestra analizada y respalda la validez del modelo lineal estimado.

**Tabla 4.** Análisis de varianza

Fuente	gl	F	p
Regresión	1	34.834	< .001
Residuo	132	—	—
Total	133	—	—

*Nota.* Variable dependiente: Autoeficacia académica. Predictor: Dependencia de la IA.

Según la Tabla 5, se observan los coeficientes del modelo de regresión lineal abordados. La dependencia de la IA predice de manera significativa la autoeficacia académica,  $B = -1.816$ ,  $EE = 0.308$ ,  $t = -5.902$ ,  $p < .001$ . El coeficiente estandarizado indica un efecto negativo de magnitud moderada,  $\beta = -0.457$ . Esto significa que, a mayor dependencia de la IA, menor nivel de autoeficacia académica. En términos prácticos, por cada punto adicional en la puntuación de dependencia a la IA, la autoeficacia académica disminuye en 1.816 puntos. El intervalo de confianza al 95 %  $[-2.424; -1.207]$  no incluye el valor cero, lo que confirma la estabilidad y significancia del efecto estimado. La constante del modelo fue significativa,  $B = 86.864$ ,  $p < .001$ , lo que representa el valor estimado de autoeficacia cuando la dependencia a la IA es igual a cero. Estos resultados respaldan la existencia de una relación predictiva inversa entre ambas variables en la muestra analizada.

**Tabla 5.** Coeficientes del modelo de regresión lineal

Variable	B	EE	$\beta$	t	p	IC 95 %
Constante	86.864	4.758	—	18.258	< .001	[77.453; 96.275]
Dependencia de la IA	-1.816	0.308	-0.457	-5.902	< .001	[-2.424; -1.207]

La Tabla 6 presenta los estadísticos de residuos del modelo. Los residuos estandarizados oscilaron entre  $-2.515$  y  $1.951$ , valores que se sitúan dentro del rango aceptable de  $\pm 3$  para supuestos de normalidad aproximada. Los residuos estudentizados mostraron un comportamiento similar, con un mínimo de  $-2.561$  y un máximo de  $1.986$ , lo que indica ausencia de valores extremos severos. La distancia de Cook alcanzó un máximo de  $0.122$ , claramente inferior al criterio conservador de  $1$ , lo que descarta la presencia de casos influyentes que distorsionen la estimación. La distancia de Mahalanobis presentó un valor máximo de  $6.218$ , sin evidenciar observaciones multivariadas atípicas críticas en el modelo con un solo predictor. En conjunto, estos resultados respaldan la estabilidad del modelo y el cumplimiento de los supuestos básicos de regresión lineal.

**Tabla 6.** Resumen de estadísticos de residuos del modelo de regresión

Indicador	Mínimo	Máximo
Residuo estandarizado	$-2.515$	$1.951$
Residuo estudentizado	$-2.561$	$1.986$
Distancia de Mahalanobis	$0.000$	$6.218$
Distancia de Cook	$0.000$	$0.122$

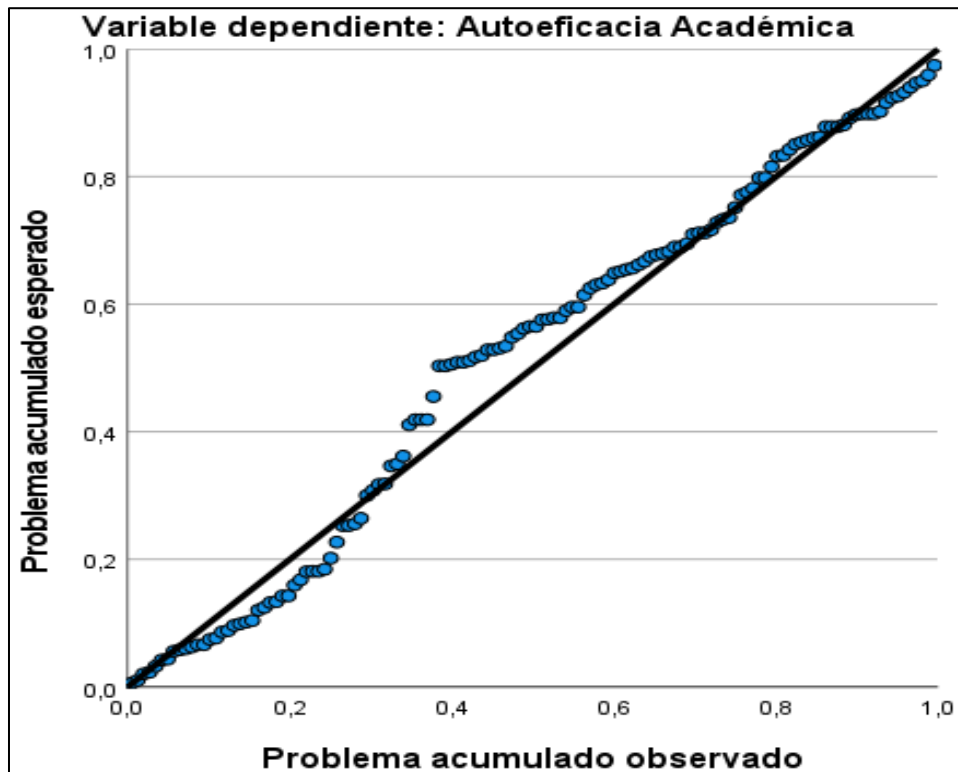
La Tabla 7 presenta la comparación entre la estimación clásica por mínimos cuadrados ordinarios y la estimación con errores estándar robustos tipo HC3. El coeficiente de la dependencia a la IA se mantiene idéntico en ambos procedimientos ( $B = -1.816$ ), lo que confirma la estabilidad del parámetro estimado. La corrección robusta incrementa ligeramente el error estándar, lo que reduce el valor  $t$ , aunque el efecto permanece estadísticamente significativo con  $p < .001$ . Este resultado indica que la relación predictiva inversa entre dependencia de la IA y autoeficacia académica se mantiene estable aun cuando se corrige la estimación de la varianza ante posibles desviaciones de homocedasticidad, lo que respalda la consistencia inferencial del modelo.

**Tabla 7.** Comparación de coeficientes del modelo de regresión bajo estimación clásica (OLS) y errores estándar robustos tipo HC3

Variable	B	EE OLS	EE HC3	t OLS	t HC3	p HC3
Constante	$86.864$	$4.758$	$5.17$	$18.258$	$16.802$	$< .001$
Dependencia de la IA	$-1.816$	$0.308$	$0.344$	$-5.902$	$-5.276$	$< .001$

La Figura 1 muestra el gráfico P-P normal de los residuos estandarizados del modelo de regresión lineal. Se observa que los puntos siguen de manera cercana la línea diagonal de referencia a lo largo de la mayor parte del rango de probabilidades acumuladas, lo que indica una distribución aproximadamente normal de los residuos. Las desviaciones son leves y se concentran en los extremos de la distribución, sin evidenciar curvaturas pronunciadas ni patrones sistemáticos que sugieran asimetría severa o colas extremas. Este comportamiento respalda el cumplimiento aproximado del supuesto de normalidad, lo cual resulta consistente con el tamaño muestral y con la ausencia de valores atípicos influyentes previamente identificados. En conjunto, la evidencia gráfica confirma que la estimación del modelo no se ve comprometida por desviaciones sustantivas de normalidad en los residuos.

*Figura 1. Gráfico P-P normal de los residuos estandarizados del modelo de regresión*



## Discusión

Los resultados evidenciaron que la dependencia de la inteligencia artificial predice de manera significativa la autoeficacia académica en estudiantes de ingeniería de una universidad peruana. El modelo explicó el 20.9 % de la varianza de la autoeficacia ( $R^2 = 0.209$ ) y presentó un efecto estandarizado negativo moderado ( $\beta = -0.457$ ;  $p < .001$ ), lo que indica que incrementos en la dependencia a la IA se asocian con una disminución proporcional en este tipo de autoeficacia. Este patrón es consistente con los hallazgos de [Estrada-Araoz et al. \(2025\)](#), quienes reportaron una relación inversa y significativa entre ambas variables ( $r = -0.299$ ;  $p < 0.05$ ), aunque mediante análisis correlacional. En contraste, [Morales-García et al. \(2025\)](#) encontraron que la autoeficacia específica para el uso de IA predijo positivamente la dependencia tecnológica ( $\beta = 0.610$ ;  $p < .001$ ). Esta discrepancia responde, principalmente, a diferencias en la naturaleza del constructo evaluado; mientras aquel estudio examinó autoeficacia instrumental vinculada al manejo de IA, el presente trabajo analizó la autoeficacia académica de forma general. Esta diferencia conceptual es relevante al momento de interpretar la dirección del efecto identificado.

Desde la conceptualización de [Morales-García et al. \(2024\)](#), la dependencia de la IA se caracteriza por vulnerabilidad, búsqueda persistente de validación externa y necesidad recurrente de asistencia automatizada. Este patrón reconfigura la forma en que el estudiante regula su desempeño académico. La externalización sistemática de procesos analíticos puede reducir la acumulación de experiencias directas de dominio, elemento central en la consolidación de la autoeficacia académica ([Bandura, 1997](#); [Dibenedetto y Schunk, 2022](#)). Estudios recientes que abordan la sobredependencia tecnológica han

documentado que la delegación reiterada de tareas cognitivas se asocia con menor compromiso intelectual y debilitamiento de habilidades académicas progresivas (Miranda et al., 2025; Abubakar et al., 2025). En este sentido, la mediación continua del rendimiento por parte de la IA puede influir en la atribución interna del éxito y, por lo tanto, en la sensación de control sobre el rendimiento académico. Esta falta de regulación puede llegar a afectar la autoeficacia de los estudiantes.

Sobre el efecto encontrado, se alinea con la literatura que ha reportado consecuencias cognitivas y motivacionales por el uso intensivo de IA en la educación superior. Estudios recientes han demostrado que la exposición prolongada a la IA se puede relacionar con la disminución del pensamiento independiente, la fatiga cognitiva y la pérdida gradual de habilidades académicas, sobre todo cuando se utiliza como sustituto del esfuerzo mental (Tian y Zhang, 2025; Zhang et al., 2024). Además, Abubakar et al. (2025) señalan que la sobredependencia de la IA puede afectar negativamente el aprendizaje si no existen marcos institucionales que controlen su uso. Esto lleva a la externalización rutinaria de los procesos cognitivos, disminuyendo el compromiso cognitivo y el desarrollo de habilidades profundas (Karamuk, 2025). En línea con lo anterior, el estudio actual proporciona evidencia adicional de que dicha dependencia es predictiva de la autoeficacia académica, un constructo que históricamente se ha reconocido como un predictor fuerte de persistencia y rendimiento en la universidad (Gore, 2006; Khine y Nielsen, 2022). En estudiantes de ingeniería, donde el aprendizaje se organiza en torno a la resolución autónoma de problemas tecnológicos, esta vinculación cobra especial sentido formativo.

Los resultados indican que la incorporación de IA en programas de ingeniería se debe acompañar de estrategias pedagógicas que mantengan la autorregulación y la atribución interna del éxito académico. La literatura actual sugiere que los impactos negativos relacionados con la sobredependencia se pueden mitigar con marcos institucionales transparentes, políticas de uso responsable y códigos éticos definidos (Abubakar et al., 2025; Ofosu-Asare, 2025). Además, investigaciones señalan que el uso pedagógico de la IA necesita cambios curriculares para enfocarse en actividades de creación, resolución gradual de problemas y metacognición (Kuka et al., 2022; Samala et al., 2025). Así, se refuerza y estimula el pensamiento crítico y la autonomía de los estudiantes universitarios.

Por otra parte, estudios que han abordado la dependencia de la IA muestran que variables como el estrés académico, el pensamiento crítico y las expectativas de rendimiento pueden actuar como variables que refuerzan su impacto en la autoeficacia académica (Acosta-Enriquez et al., 2025; Wang y Xu, 2026). Por ello, las intervenciones educativas deben centrarse en fortalecer competencias cognitivas y motivacionales que sostienen el desempeño autónomo. Considerando que la autoeficacia académica constituye un predictor robusto de persistencia y resultados universitarios (Gore, 2006; Dibenedetto y Schunk, 2022).

Futuras investigaciones deberían incluir diseños longitudinales para verificar la estabilidad de la capacidad predictiva encontrada y analizar cambios en la autoeficacia académica a través del tiempo. Es de interés elaborar modelos estructurales que incluyan variables mediadoras como autorregulación, ansiedad hacia la IA o motivación intrínseca y comparar los modelos entre disciplinas y grupos de edad. Además, la incorporación de medidas objetivas de rendimiento académico podría mejorar la capacidad explicativa del modelo.

El estudio presenta limitaciones que deben considerarse. El diseño transversal impide

establecer inferencias causales, por lo que la capacidad predictiva identificada debe interpretarse en términos estadísticos. Asimismo, el uso de instrumentos de autorreporte puede introducir sesgos de percepción. Finalmente, la muestra se circunscribe a una universidad peruana, lo que limita la generalización a otros contextos académicos con distintos niveles de integración tecnológica.

## Conclusiones

Los resultados confirman que la dependencia de la inteligencia artificial constituye un predictor significativo de la autoeficacia académica en estudiantes de ingeniería de una universidad pública peruana. El modelo de regresión lineal explicó el 20.9 % de la varianza de la autoeficacia académica, con un efecto negativo moderado, lo que indica que mayores niveles de dependencia se relacionan con menores creencias de competencia personal. Este hallazgo amplía la evidencia previa centrada en efectos cognitivos y demuestra que la subordinación psicológica a herramientas de inteligencia artificial también impacta variables motivacionales vinculadas al desempeño académico. En términos teóricos, los resultados se alinean con el marco de la autoeficacia, el cual sostiene que las creencias de competencia se fortalecen a partir de experiencias directas de dominio y atribución interna del logro.

Desde el punto de vista educativo, los hallazgos sugieren que la incorporación de inteligencia artificial en la formación en ingeniería debe acompañarse de estrategias pedagógicas orientadas a preservar la autonomía cognitiva y la autorregulación del aprendizaje. Es indispensable promover prácticas que exijan análisis propio, resolución independiente de problemas y reflexión crítica en los estudiantes. De esta manera, el uso de inteligencia artificial puede integrarse como un recurso complementario sin debilitar la percepción de su capacidad académica.

## Acerca de

**Contribución de los autores:** Los autores contribuyeron a la conceptualización del estudio, desarrollo metodológico, análisis e interpretación de los datos, redacción del manuscrito y revisión crítica de su contenido intelectual.

**Financiamiento:** Los autores declaran que no recibieron financiamiento para esta investigación.

**Certificación ética:** El protocolo del presente estudio fue sometido a revisión y aprobado por el Comité de Ética en Investigación de la Universidad, en cumplimiento de los principios éticos y normativas institucionales aplicables.

## Referencias

Abubakar, S., Jeilani, A., & Yusuf, M. (2025). The role of over-reliance on AI in the negative consequences of student learning: The moderating effects of ethical concerns

and institutional policies. *Cogent Education*, 12(1), 2591503.

<https://doi.org/10.1080/2331186X.2025.2591503>

Acosta-Enriquez, B. G., Ballesteros, M. A. A., Guzman Valle, M. D. L. A., Morales Angaspilco, J. E., Aquino Lalupú, J. D. R., Jaico, J. L. B., Germán Reyes, N. C., Alarcón García, R. E., & Castillo, W. E. J. (2025). The mediating role of academic stress, critical thinking and performance expectations in the influence of academic self-efficacy on AI dependence: Case study in college students. *Computers and Education: Artificial Intelligence*, 8, 100381. <https://doi.org/10.1016/j.caeai.2025.100381>

Adams, A. M., Wilson, H., Money, J., Palmer-Conn, S., & Fearn, J. (2020). Student engagement with feedback and attainment: the role of academic self-efficacy. *Assessment and Evaluation in Higher Education*, 45(2), 317-329.

<https://doi.org/10.1080/02602938.2019.1640184>

Afari, E., & Ahmed Eksail, F. A. (2022). Relationship between learning environment and academic achievement: Mediating role of academic self-efficacy. In M. S. Khine & T. Nielsen (Eds.), *Academic self-efficacy in education: Nature, assessment, and research* (pp. 179–190). Springer. [https://doi.org/10.1007/978-981-16-8240-7\\_11](https://doi.org/10.1007/978-981-16-8240-7_11)

Ateeq, A., Alaghbari, M. A., Alzoraiki, M., Milhem, M., & Hasan Beshr, B. A. (2024). Empowering academic success: Integrating AI tools in university teaching for enhanced assignment and thesis guidance. In *2024 ASU International Conference in Emerging Technologies for Sustainability and Intelligent Systems (ICETISIS)* (pp. 297–301). IEEE. <https://doi.org/10.1109/ICETISIS61505.2024.10459686>

Ato, M., López-García, J. J., & Benavente, A. (2013). A classification system for research designs in psychology. *Annals of Psychology*, 29(3), 1038-1059. <https://doi.org/10.6018/analesps.29.3.178511>

Bandura, A. (1997). *Self-efficacy: The exercise of control*. W. H. Freeman. [https://www.academia.edu/28274869/Albert\\_Bandura\\_Self\\_Efficacy\\_The\\_Exercise\\_of\\_Control\\_W\\_H\\_Freeman\\_and\\_Co\\_1997\\_pdf](https://www.academia.edu/28274869/Albert_Bandura_Self_Efficacy_The_Exercise_of_Control_W_H_Freeman_and_Co_1997_pdf)

Cui, P., & Alias, B. S. (2024). Opportunities and challenges in higher education arising from AI: A systematic literature review (2020–2024). *Journal of Infrastructure, Policy and Development*, 8(11), 8390. <https://doi.org/10.24294/jipd.v8i11.8390>

Deng, R., Jiang, M., Yu, X., Lu, Y., & Liu, S. (2025). Does ChatGPT enhance student learning? A systematic review and meta-analysis of experimental studies. *Computers & Education*, 227, 105224. <https://doi.org/10.1016/j.compedu.2024.105224>

Dibenedetto, M. K., & Schunk, D. H. (2022). Assessing Academic Self-efficacy. In *Academic Self-efficacy in Education: Nature, Assessment, and Research* (pp. 11-37). [https://doi.org/10.1007/978-981-16-8240-7\\_2](https://doi.org/10.1007/978-981-16-8240-7_2)

Estrada-Araoz, E. G., Mamani-Roque, M., Quispe-Aquise, J., Manrique-Jaramillo, Y. V., & Cruz-Laricano, E. O. (2025). Academic self-efficacy and dependence on artificial intelligence in a sample of university students. *Sapienza*, 6(1), e25008. <https://doi.org/10.51798/sijis.v6i1.916>

Galleguillos-Herrera, P., & Olmedo-Moreno, E. (2019). Academic self-efficacy and motivation: a measurement for the achievement of school objectives. *European Journal of Investigation in Health, Psychology and Education*, 9(3), 119-135.

<https://doi.org/10.30552/ejihpe.v9i3.329>

Gore, P. A. (2006). Academic self-efficacy as a predictor of college outcomes: Two incremental validity studies. *Journal of Career Assessment*, 14(1), 92-115.

<https://doi.org/10.1177/1069072705281367>

Huang, T., & Wu, C. (2025). The chain mediating effect of academic anxiety and performance expectations between academic self-efficacy and generative AI reliance. *Computers and Education Open*, 9, 100275. <https://doi.org/10.1016/j.caeo.2025.100275>

Jia, W., Pan, L., & Neary, S. (2025). Effect of GenAI Dependency on University Students' Academic Achievement: The Mediating Role of Self-Efficacy and Moderating Role of Perceived Teacher Caring. *Behavioral Sciences*, 15(10), 1348.

<https://doi.org/10.3390/bs15101348>

Karamuk, E. (2025). The automation trap: Unpacking the consequences of over-reliance on AI in education and its hidden costs. In *Pitfalls of AI Integration in Education: Skill Obsolescence, Misuse, and Bias* (pp. 151-174). <https://doi.org/10.4018/979-8-3373-0122-8.ch007>

Khine, M. S., & Nielsen, T. (2022). Current Status of Research on Academic Self-efficacy in Education. In *Academic Self-efficacy in Education: Nature, Assessment, and Research* (pp. 3-8). [https://doi.org/10.1007/978-981-16-8240-7\\_1](https://doi.org/10.1007/978-981-16-8240-7_1)

Klingbeil, A., Grützner, C., & Schreck, P. (2024). Trust and reliance on AI—An experimental study on the extent and costs of overreliance on AI. *Computers in Human Behavior*, 160, 108352. <https://doi.org/10.1016/j.chb.2024.108352>

Kuka, L., Hörmann, C., & Sabitzer, B. (2022). Teaching and Learning with AI in Higher Education: A Scoping Review. In *Lecture Notes in Networks and Systems* (Vol. 456, pp. 551-571). [https://doi.org/10.1007/978-3-031-04286-7\\_26](https://doi.org/10.1007/978-3-031-04286-7_26)

Miranda, J. P. P., Cruz, M. A. D., Fernandez, A. B., Balahadia, F. F., Aviles, J. S., Caro, C. A., Liwanag, I. G., & Gaña, E. P. (2025). Erosion of critical academic skills due to AI dependency among tertiary students: A path analysis. In *Pitfalls of AI Integration in Education: Skill Obsolescence, Misuse, and Bias* (pp. 25-48).

<https://doi.org/10.4018/979-8-3373-0122-8.ch002>

Morales-García, W. C., Sairitupa-Sanchez, L. Z., Morales-García, S. B., & Morales-García, M. (2024). Development and validation of a scale for dependence on artificial intelligence in university students. *Frontiers in Education*, 9.

<https://doi.org/10.3389/feduc.2024.1323898>

Morales-García, W. C., Sairitupa-Sanchez, L. Z., Flores-Paredes, A., Pascual-Mariño, J., & Morales-García, M. (2025). Influence of Self-Efficacy in the Use of Artificial Intelligence (AI) and Anxiety Toward AI Use on AI Dependence Among Peruvian University Students. *Data and Metadata*, 4, 210. <https://doi.org/10.56294/dm2025210>

- Ofosu-Asare, Y. (2025). Guiding the future: developing an ethical framework for generative AI use in education. *International Journal of Information and Learning Technology*, 1-19. <https://doi.org/10.1108/IJILT-06-2024-0113>
- Samala, A. D., Rawas, S., Wang, T., Reed, J. M., Kim, J., Howard, N.-J., & Ertz, M. (2025). Unveiling the landscape of generative artificial intelligence in education: a comprehensive taxonomy of applications, challenges, and future prospects. *Education and Information Technologies*, 30(3), 3239-3278. <https://doi.org/10.1007/s10639-024-12936-0>
- Schunk, D. H., & DiBenedetto, M. K. (2021). Chapter Four - Self-efficacy and human motivation. In A. J. Elliot (Ed.), *Advances in Motivation Science* (Vol. 8, pp. 153-179). Elsevier. <https://doi.org/10.1016/bs.adms.2020.10.001>
- Singh, S. V., & Hiran, K. K. (2022). The Impact of AI on Teaching and Learning in Higher Education Technology. *Journal of Higher Education Theory and Practice*, 22(13), 135-148. <https://doi.org/10.33423/jhetp.v22i13.5514>
- Sri Tulasi, T., & Inayath Ahamed, S. B. (2024). Artificial intelligence effects on student learning outcomes in higher education. In *2024 Ninth International Conference on Science Technology Engineering and Mathematics (ICONSTEM)* (pp. 1–5). IEEE. <https://doi.org/10.1109/ICONSTEM60960.2024.10568868>
- Tian, J., & Zhang, R. (2025). Learners' AI dependence and critical thinking: The psychological mechanism of fatigue and the social buffering role of AI literacy. *Acta Psychologica*, 260, 105725. <https://doi.org/10.1016/j.actpsy.2025.105725>
- Wang, Y., & Xu, S. (2026). Relationship between artificial intelligence tool usage experience and academic stress among college students: Mediating role of loneliness and moderating role of academic self-efficacy [Article]. *Acta Psychologica*, 263, Article 106220. <https://doi.org/10.1016/j.actpsy.2026.106220>
- Zhang, S., Zhao, X., Zhou, T., & Kim, J. H. (2024). Do you have AI dependency? The roles of academic self-efficacy, academic stress, and performance expectations on problematic AI usage behavior. *International Journal of Educational Technology in Higher Education*, 21(1), 34. <https://doi.org/10.1186/s41239-024-00467-0>