

ISSN-e: 3078-6983

DOI: 10.47460/noesis.v3i4

Revista Noesis



Volumen 3, Número 6, 2026

Renace la educación cuando la sociedad comprende que el conocimiento no es un complemento del desarrollo, sino su fundamento más imprescindible



REVISTA NOESIS

Revista Científica en Educación y Ciencias Sociales

Publicación continua

Volumen 3 | ENERO-ABRIL

DOI: 10.47460/noesis ISSN-e: 3078-6983

Nuestra Portada



FUENTE: canva.com

LICENCIA: 03422-17578080

Esta edición reúne investigaciones sobre educación superior, inteligencia artificial, aprendizaje autónomo, teletrabajo docente y pedagogías digitales emergentes, abordando los desafíos actuales de la enseñanza, el desempeño académico y la transformación institucional en contextos universitarios.

Visite nuestra revistas en:

<https://noesis.autanabooks.com/>

Equipo Técnico

Administración web y Metadatos

Ing. Ángel Lezama (Quito, Ecuador).

a2lezama@gmail.com

Diseño gráfico y maquetación

Adrián Hauser (AutanaBooks, Ecuador).

adrian.hauser@gmail.com

Traductor

Fausto Bartolotta

Via Francesco Crispi, 309/A

98028 Santa Teresa Di Riva,

Provincia Messina

Italia

email: fbartolotta@gmail.com

Nota editorial

Los artículos, opiniones y colaboraciones publicados en esta revista no representan necesariamente la filosofía informativa o institucional de AutanaBooks y pueden ser reproducidos con previa autorización del Editor. En caso de reproducción, se ruega citar la fuente y enviar copias del medio utilizado a AutanaBooks, Sector Mitad del Mundo, Quito, Ecuador.

Editor

Dr. José Calizaya López
0000-0002-8763-5513
jcalizayal@unsa.edu.pe
Arequipa, Perú.

Co-editor

Dra. Franyelit Suárez
0000-0002-8763-5513
editorial@autanabooks.com
Autanabooks, Quito, Ecuador.

Directorio de Noesis, Revista Científica en Educación y Ciencias Sociales

Comité académico

Dr. Luis Rosales. Universidad Nacional Experimental Politécnica “Antonino José de Sucre”, Vice Rectorado Puerto Ordaz, Venezuela.

luis.rosals2@gmail.com

0000-0002-7787-9178

Dr. José García-Arroyo. Universidad Nacional de Educación a Distancia (UNED), España.

jagarcia@uees.edu.ec

0000-0001-9905-1374

Dr. Valentina Millano. Centro de Estudios de Corrosión (CEC), Universidad del Zulia, Venezuela.

millanov@fing.luz.edu.ve, millanov@gmail.com

0000-0001-6138-4747

PhD. Yajaira Lizeth Carrasco Vega. Universidad Nacional de Cañete, Lima, Perú.

ycarrasco@undc.edu.pe

0000-0003-4337-6684

Dr. Edwin Flórez Gómez. Universidad de Puerto Rico en Mayagüez, Mayagüez, Puerto Rico.

edwin.florez@upr.edu

0000-0003-4142-3985

Dr. Hilda Márquez. Universidad Metropolitana de Quito, Quito, Ecuador.

amarquez@umet.edu.ec

0000-0002-7958-420X

Dr. Diana Cristina Morales Urrutia. Universidad Técnica de Ambato, Ambato, Ecuador.

dc.moralesu@uta.edu.ec

0000-0002-9693-3192

Dr. Hernan Mauricio Quisimain Santamaria. Universidad Técnica de Ambato, Ambato, Ecuador.

hernanmquisimalin@uta.edu.ec

0000-8491-8326

Dr. Jorge Mauricio Fuentes Fuentes. Universidad Central del Ecuador, Quito, Ecuador.

jmfuentes@uce.edu.ec

0000-0003-0342-643X

Dr. Yelka Martina López Cuadra. Universidad Nacional Intercultural Fabiola Salazar Leguía de Bagua, Bagua, Perú.

ylopez@unibagua.edu.pe

0000-0002-3522-0658

Dra. Irela Perez Magin. Universidad Politécnica de Puerto Rico, San Juan, Puerto Rico.

iperezmagin@pupr.edu

0000-0003-3329-4503

PhD. Alejandro Suarez-Alvites. Universidad Nacional Mayor de San Marcos, Lima, Perú.

alejandrosualvites@hotmail.com

0000-0002-9397-057X

Dr. Janio Jadán. Universidad Tecnológica Indoamérica, Quito, Ecuador.

janiojadan@uti.edu.ec

0000-0002-3616-2074

Dr. Neris Ortega. Universidad Metropolitana de Quito, Quito, Ecuador.

nortega@umet.edu.ec

0000-0001-5643-5925

Dr. Juan Carlos Alvarado Ibáñez. Universidad Nacional Intercultural Fabiola Salazar Leguía de Bagua, Bagua, Perú.

jalvarado@unibagua.edu.pe

0000-0002-6413-3457

Comité científico

Mgt. Juan Segura. Universidad Tecnológica Indoamérica, Quito, Ecuador.

juansegura@uti.edu.ec

0000-0002-0625-0719

Dr. Jairo José Rondón Contreras. Instituto Tecnológico de Santo Domingo, República Dominicana.

rondonjjx@gmail.com / jairo.rondon@intec.edu.do

0000-0002-9738-966X

Dr. Angel Gonzalez Lizardo. Polytechnic University of Puerto Rico, San Juan, Puerto Rico.

agonzalez@pupr.edu

0000-0002-0722-1426

Dr. Wilfredo Fariñas Coronado. Polytechnic University of Puerto Rico, San Juan, Puerto Rico.

wfarinascoronado@pupr.edu

0000-0003-2095-5755

Dra. Diana Cristina Morales Urrutia. Universidad Técnica de Ambato, Ambato, Ecuador.

dc.moralesu@uta.edu.ec

0000-0002-9693-3192

Dr. Carlos Alberto Gómez Cano. Corporación Unificada Nacional de Educación Superior, CUN, Florencia, Caquetá, Colombia.

carlos_gomezca@cun.edu.co, carlosgomez325@gmail.com

0000-0003-0425-7201

Mgr. Benjamín David Carril Verastegui. Universidad Nacional de Trujillo, Trujillo, Perú.

bcarril@unitru.edu.pe

0000-0001-6010-0175

Índice (Volumen 3, Tomo 6 // enero-abril 2026)

- 9** Teresa Mercedes Verástegui Gálvez, Abel Antonio Valdivia Rodríguez. *Trabajo remoto y desempeño docente en la educación superior: un análisis cuantitativo de productividad, compromiso y clima institucional.*
- 20** Maria Cecilia Terry Borjas. *Relación entre las inteligencias múltiples y las estrategias de aprendizaje autónomo en estudiantes de ingeniería.*
- 31** Renzo Enrique Polo-Moreano. *Perspectivas de la educación universitaria en tiempos de inteligencia artificial: una aproximación cuantitativa al impacto educativo, las competencias digitales y la actitud tecnológica.*
- 42** Pablo Rivera Ramos. *Dependencia de herramientas de inteligencia artificial y su impacto en la profundidad del aprendizaje en estudiantes universitarios: un análisis desde la autorregulación académica.*
- 53** Wilfredo Fariñas-Coronado. *Pedagogías del error en entornos digitales: el valor formativo del fallo en la construcción del aprendizaje profundo.*

Editorial

El renacer de la educación en la sociedad del conocimiento

Vivimos en una época de profundas transformaciones sociales, tecnológicas y culturales. La inteligencia artificial, la digitalización, la automatización y los cambios en las dinámicas económicas han modificado la forma en que las personas trabajan, se relacionan y construyen su futuro. Sin embargo, en medio de este vertiginoso escenario, persiste una verdad inalterable: ninguna sociedad puede aspirar al progreso sostenible si descuida la educación y menos aún si subestima el valor del conocimiento.

Durante mucho tiempo, el conocimiento ha sido percibido, en algunos contextos, como un elemento accesorio, un complemento deseable, pero no esencial. Se ha privilegiado la inmediatez sobre la reflexión, la rapidez sobre el rigor y la cantidad sobre la calidad. La educación ha sido reducida, en ocasiones, a la simple transmisión de contenidos o a la obtención de credenciales, olvidando que su verdadera misión consiste en formar seres humanos capaces de comprender la realidad, cuestionarla y transformarla.

El desafío de nuestro tiempo no consiste únicamente en enseñar más contenidos o incorporar más tecnologías a las aulas. El verdadero desafío es restituir al conocimiento el lugar que le corresponde en la vida social y educativa. Significa reconocer que la educación no debe preparar únicamente para el empleo, sino también para la ciudadanía, la convivencia, la ética y la construcción de un futuro compartido.

Que este sea, entonces, el tiempo del renacer de la educación. Un renacer que nos recuerde que el conocimiento no es un complemento del progreso, sino su condición indispensable; que educar no es solo transmitir información, sino despertar conciencias; y que invertir en educación y en conocimiento es, en esencia, apostar por la dignidad humana y por la construcción de sociedades más justas, libres y sostenibles.

Dra. Franyelit Suárez
Editora



**AutanaBooks**
Знання та Вісність

Artículo de investigación

<https://doi.org/10.47460/noesis.v3i6.48>

Trabajo remoto y desempeño docente en la educación superior: un análisis cuantitativo de productividad, compromiso y clima institucional

Teresa Mercedes Verástegui Gálvez*
<https://orcid.org/0009-0008-5693-6023>
teresa.verastegui@unmsm.edu.pe
Universidad Nacional Mayor de San Marcos
Lima, Perú

Abel Antonio Valdivia Rodríguez
<https://orcid.org/0009-0007-3601-6054>
abel.valdivia@unmsm.edu.pe
Universidad Nacional Mayor de San Marcos
Lima, Perú

Autor de correspondencia: teresa.verastegui@unmsm.edu.pe

Recibido: (22/10/2025), Aceptado: (19/12/2025)

Resumen. En el presente estudio se analizó el efecto del trabajo remoto sobre el desempeño docente en educación superior, considerando el papel del compromiso profesional y el clima institucional como factores explicativos complementarios. Se empleó un diseño cuantitativo de alcance explicativo con una muestra de 428 docentes universitarios. Los resultados del análisis de regresión múltiple evidenciaron que el modelo explica el 33% de la varianza del desempeño docente. Si bien el trabajo remoto mostró un efecto positivo y significativo, el compromiso docente emergió como el predictor de mayor peso relativo, seguido del clima institucional. El análisis de mediación indicó que parte del impacto del trabajo remoto se canaliza a través de variables motivacionales y organizacionales. Los hallazgos sugieren que la sostenibilidad del desempeño académico en entornos digitales depende de la interacción entre condiciones estructurales y factores psicosociales.

Palabras clave: trabajo remoto, desempeño docente, compromiso profesional, clima institucional.

Remote Work and Teaching Performance in Higher Education: A Quantitative Analysis of Productivity, Engagement, and Institutional Climate

Abstract. This study examined the effect of remote work on teaching performance in higher education, considering professional engagement and institutional climate as complementary explanatory factors. A quantitative explanatory design was employed with a sample of 428 university professors. Multiple regression analysis revealed that the model explains 33% of the variance in teaching performance. Although remote work showed a positive and statistically significant effect, teacher engagement emerged as the strongest predictor, followed by institutional climate. Mediation analysis indicated that part of the impact of remote work operates through motivational and organizational variables. The findings suggest that the sustainability of academic performance in digital environments depends on the interaction between structural conditions and psychosocial factors.

Keywords: remote work, teaching performance, professional engagement, institutional climate.

I. INTRODUCCIÓN

La pandemia por COVID-19 produjo una transformación sin precedentes en los sistemas de educación superior, obligando a las universidades a migrar abruptamente hacia modalidades remotas de enseñanza. Este proceso, conceptualizado como *emergency remote teaching*, evidenció diferencias sustantivas respecto a la educación en línea planificada, generando desafíos pedagógicos, tecnológicos y organizacionales [1]. A nivel global, las instituciones adoptaron estrategias digitales aceleradas para garantizar la continuidad académica, modificando estructuras laborales y dinámicas docentes tradicionales [2].

Si bien el trabajo remoto permitió sostener las actividades académicas durante la crisis sanitaria, también expuso tensiones vinculadas con la sobrecarga laboral, el agotamiento emocional y la adaptación tecnológica del profesorado [3], [4]. La evidencia sugiere que la competencia digital docente y el soporte institucional constituyen factores críticos para la eficacia del desempeño en entornos virtuales [5]. Desde el marco del modelo de Demandas y Recursos Laborales (JD-R), el equilibrio entre exigencias profesionales y recursos organizacionales explica variaciones en compromiso, bienestar y rendimiento laboral [6], [7]. En el ámbito educativo, el compromiso docente (*work engagement*) ha demostrado ser un predictor significativo del desempeño, la innovación pedagógica y la resiliencia profesional [8], [9]. No obstante, la transición al trabajo remoto modificó los patrones de interacción académica y la percepción del clima organizacional universitario.

El clima organizacional, entendido como la percepción compartida de políticas, prácticas y liderazgo dentro de una institución, influye directamente en resultados laborales y académicos [10], [11]. En contextos remotos, variables como el liderazgo digital, la confianza institucional y la comunicación organizacional adquieren especial relevancia para sostener la productividad y la cohesión académica. Asimismo, estudios recientes en educación superior han señalado que el bienestar docente durante la enseñanza remota se asocia con niveles de apoyo organizacional y claridad estructural [4], [12]. La falta de recursos adecuados puede incrementar el estrés y reducir el compromiso, afectando el rendimiento académico [13].

Pese al crecimiento de investigaciones sobre educación remota, gran parte de la literatura se ha centrado en estudios descriptivos o cualitativos, limitando el análisis estadístico de relaciones estructurales entre productividad, compromiso y clima institucional. En este escenario, se vuelve pertinente avanzar hacia enfoques cuantitativos que integren estas dimensiones bajo modelos analíticos multivariantes.

En consecuencia, el presente estudio tiene como objetivo analizar cuantitativamente la relación entre trabajo remoto, desempeño docente, compromiso laboral y clima institucional en educación superior, aportando evidencia empírica que permita comprender los factores organizacionales que inciden en la productividad académica en entornos digitales. Esta aproximación busca fortalecer la toma de decisiones basada en evidencia en procesos de transformación educativa postpandemia.

II. MARCO TEÓRICO

La transformación del trabajo académico en educación superior a partir de la pandemia no puede entenderse únicamente como un cambio tecnológico, sino como una reconfiguración estructural de las prácticas docentes, las dinámicas institucionales y la cultura organizacional universitaria. La literatura ha diferenciado claramente entre la enseñanza en línea planificada y lo que se denominó *emergency remote teaching*, subrayando que la transición abrupta respondió a una contingencia más que a un diseño pedagógico estratégico [2]. Esta distinción resulta fundamental para comprender los efectos posteriores del trabajo remoto en el desempeño docente.

A nivel internacional, las universidades implementaron respuestas digitales heterogéneas que evidenciaron diferencias en infraestructura, liderazgo y capacidad organizacional [3]. Este escenario generó un contexto de adaptación acelerada en el que el profesorado debió asumir nuevas responsabilidades tecnológicas y metodológicas, afectando su experiencia laboral y su percepción institucional. Investigaciones posteriores han mostrado que esta transición alteró la identidad profesional del docente universitario, incrementando la carga emocional y difuminando los límites entre vida personal y actividad académica [1], [4].

El desempeño docente en entornos remotos debe analizarse, por tanto, desde una perspectiva sistémica. Más allá de la productividad entendida en términos tradicionales, la eficacia académica en modalidad remota depende de la competencia digital, la autonomía profesional y la capacidad de gestionar demandas cognitivas y

tecnológicas simultáneamente [5]. En este sentido, el modelo de Demandas y Recursos Laborales (JD-R) ofrece un marco explicativo robusto al sostener que el rendimiento profesional resulta del equilibrio entre exigencias laborales y recursos disponibles [6], [7]. Cuando las demandas superan los recursos, emergen agotamiento y desmotivación; en contraste, cuando la institución provee soporte tecnológico, claridad organizacional y liderazgo efectivo, se fortalece el compromiso laboral.

El compromiso docente constituye un constructo central para comprender el impacto del trabajo remoto en educación superior. Definido como un estado positivo caracterizado por vigor, dedicación y absorción en el trabajo [13], el *work engagement* ha demostrado ser un predictor consistente del desempeño profesional y la innovación educativa [8], [9]. En contextos remotos, la autonomía puede actuar como un recurso motivacional que potencia el compromiso; sin embargo, la ausencia de apoyo organizacional o reconocimiento institucional puede debilitar este efecto y generar tensiones psicosociales [4], [12].

De forma paralela, el clima institucional emerge como un factor estructural que condiciona la experiencia del profesorado. El clima organizacional, entendido como la percepción compartida de políticas, prácticas y liderazgo dentro de una institución [10], influye directamente en resultados laborales como desempeño, satisfacción y permanencia [11]. En entornos remotos, variables como la confianza institucional, la comunicación digital efectiva y la claridad normativa adquieren mayor relevancia para sostener la cohesión académica y la productividad colectiva.

La literatura también ha evidenciado que el bienestar docente funciona simultáneamente como resultado y como predictor del desempeño sostenido. Estudios recientes han mostrado que la sobrecarga digital y la ambigüedad organizacional pueden incrementar el estrés somático y psicológico del profesorado [12], afectando su capacidad de mantener niveles óptimos de rendimiento. Desde la perspectiva del JD-R, los recursos institucionales no solo reducen el desgaste, sino que activan procesos motivacionales que impulsan el compromiso y la eficacia profesional [7].

Pese al crecimiento de investigaciones sobre educación remota en el periodo postpandémico, una parte significativa de los estudios se ha centrado en análisis descriptivos o aproximaciones cualitativas que documentan experiencias individuales [1], [3]. Resulta necesario avanzar hacia modelos cuantitativos integradores que permitan analizar de manera simultánea la interacción entre trabajo remoto, compromiso docente, clima institucional y desempeño académico. La articulación de estos constructos bajo un enfoque multivariante contribuye a comprender cómo las condiciones organizacionales modulan la productividad universitaria en entornos digitales.

De esta manera, el presente estudio se fundamenta en la integración teórica del modelo de Demandas y Recursos Laborales, el enfoque de compromiso docente y la teoría del clima organizacional, con el propósito de examinar empíricamente la relación estructural entre trabajo remoto y desempeño docente en educación superior. Este marco conceptual permite sustentar un análisis cuantitativo orientado a explicar cómo los factores institucionales y psicosociales influyen en la productividad académica en escenarios de transformación digital.

III. METODOLOGÍA

Se desarrolló un estudio cuantitativo de alcance explicativo, con diseño no experimental y corte transversal. El objetivo fue analizar la relación estructural entre trabajo remoto, compromiso docente, clima institucional y desempeño académico en instituciones de educación superior. El enfoque adoptado permitió evaluar asociaciones y efectos predictivos entre variables mediante análisis multivariante.

La muestra estuvo compuesta por 428 docentes universitarios pertenecientes a seis instituciones de educación superior (tres públicas y tres privadas), ubicadas en contextos urbanos con implementación formal de modalidades remotas o híbridas posteriores a 2020. El muestreo fue no probabilístico por conveniencia, condicionado por la autorización institucional y la voluntariedad de participación. Los criterios de inclusión consideraron: (a) experiencia mínima de un año en docencia universitaria, y (b) haber impartido al menos un semestre en modalidad remota o híbrida.

La recolección de datos se realizó mediante cuestionario en línea durante el segundo semestre académico de 2024. La participación fue anónima y voluntaria, cumpliendo con principios éticos de confidencialidad y

consentimiento informado digital. Para ello, se utilizó un cuestionario estructurado compuesto por cuatro escalas validadas internacionalmente, adaptadas al contexto de educación superior:

Trabajo remoto académico: escala de percepción sobre condiciones de trabajo remoto (autonomía, soporte tecnológico, claridad organizacional), compuesta por 10 ítems en escala Likert de cinco puntos (1 = totalmente en desacuerdo, 5 = totalmente de acuerdo).

Compromiso docente (Work Engagement): versión abreviada del *Utrecht Work Engagement Scale (UWES-9)*, que evalúa vigor, dedicación y absorción.

Clima institucional: escala de percepción organizacional basada en dimensiones de liderazgo, comunicación y apoyo institucional (12 ítems).

Desempeño docente percibido: escala de autoevaluación de productividad académica (docencia, innovación pedagógica y cumplimiento institucional), compuesta por 8 ítems.

La consistencia interna fue evaluada mediante alfa de Cronbach y coeficiente omega. Todos los constructos presentaron valores superiores a 0,80, indicando adecuada fiabilidad interna.

A. Análisis estadístico

El análisis estadístico se realizó en tres etapas:

Etapa 1: A través de un análisis descriptivo y verificación de supuestos se calcularon medias, desviaciones estándar, asimetría y curtosis para evaluar normalidad univariada. La ausencia de colinealidad fue verificada mediante el índice de tolerancia y el factor de inflación de la varianza (VIF).

Etapa 2: Elaborando un análisis factorial confirmatorio (AFC) se evaluó la estructura factorial de los constructos mediante modelamiento de ecuaciones estructurales (SEM) con estimación por máxima verosimilitud robusta. Se consideraron índices de ajuste estándar (CFI, TLI, RMSEA y SRMR).

Etapa 3: A través de un modelo estructural se estimó un modelo de relaciones causales en el que el trabajo remoto actuó como variable exógena, el compromiso docente y el clima institucional como variables mediadoras, y el desempeño docente como variable endógena. Se analizaron efectos directos, indirectos y totales.

El nivel de significancia estadística se estableció en $p < 0,05$.

Por otra parte, el estudio se desarrolló conforme a principios de investigación responsable en educación superior. No se recopilaron datos sensibles ni identificadores personales. La participación fue voluntaria y los datos fueron utilizados exclusivamente con fines académicos.

IV. RESULTADOS

La Tabla 1 presenta los estadísticos descriptivos y las correlaciones entre las variables centrales del estudio. En términos descriptivos, se observan medias superiores al punto medio de la escala en todas las dimensiones evaluadas, lo que indica una percepción globalmente favorable del trabajo remoto, el compromiso docente y el clima institucional en la muestra analizada. El desempeño docente muestra la media más elevada ($M = 4,87$), con una desviación estándar relativamente baja ($DE = 0,27$), lo que sugiere una concentración de respuestas en los niveles altos de la escala.

En cuanto a las asociaciones bivariadas, todas las variables presentan correlaciones positivas con el desempeño docente. El compromiso docente exhibe la relación más fuerte ($r = 0,460$), seguido del trabajo remoto ($r = 0,444$), mientras que el clima institucional muestra una asociación moderada ($r = 0,377$). Este patrón indica que, aunque las condiciones estructurales del trabajo remoto y el entorno organizacional son relevantes, los factores motivacionales asociados al compromiso profesional presentan mayor poder explicativo en relación con el rendimiento académico.

La magnitud de las correlaciones, si bien no es extrema, resulta consistente con investigaciones en educación superior, donde el desempeño docente suele explicarse mediante la interacción de múltiples variables contextuales y psicológicas. En conjunto, estos resultados preliminares justifican el análisis multivariante

posterior, orientado a examinar el efecto conjunto y estructural de estas dimensiones sobre la productividad académica en entornos remotos.

Tabla 1. Estadísticos descriptivos y correlaciones con desempeño docente.

Variable	Media	Desv_Est	Correlación con desempeño
Trabajo remoto	3,617581	0,568255	0,443615
Compromiso docente	3,786459	0,558654	0,460155
Clima institucional	3,706907	0,531252	0,377414
Desempeño docente	4,872496	0,269562	1

Fuente: Elaboración propia.

A. Análisis bivariado

La Figura 1 muestra la relación entre la percepción del trabajo remoto y el desempeño docente en educación superior. La dispersión de los datos evidencia una tendencia ascendente, lo que indica que mayores valoraciones de las condiciones de trabajo remoto se asocian con niveles más altos de desempeño académico. La línea de regresión confirma esta dirección positiva, con una pendiente moderada y un coeficiente de determinación ($R^2 = 0,1968$) que sugiere que aproximadamente el 20% de la variabilidad en el desempeño docente puede explicarse por la percepción del trabajo remoto.

Si bien la magnitud del efecto no es elevada, resulta estadísticamente relevante y conceptualmente consistente con el marco teórico adoptado. El patrón observado indica que el trabajo remoto constituye un recurso organizacional que favorece el rendimiento docente, aunque no opera como único determinante del desempeño. La dispersión residual sugiere la intervención de factores adicionales, como el compromiso profesional y el clima institucional, que pueden potenciar o atenuar este efecto.

En términos interpretativos, los resultados respaldan la idea de que la modalidad remota, cuando es percibida como estructurada y funcional, contribuye positivamente a la productividad académica. No obstante, el tamaño del efecto indica que su impacto se encuentra mediado por variables motivacionales y organizacionales más profundas, lo que justifica el análisis multivariante desarrollado posteriormente.




Fig. 1. Relación encontrada entre el desempeño docente y la percepción del trabajo remoto.

La Figura 2 muestra la relación entre el compromiso docente y el desempeño académico en educación superior. La dispersión de los datos evidencia una tendencia ascendente más pronunciada en comparación con la observada en la Figura 1, lo que sugiere una asociación más robusta entre ambas variables. La línea de regresión confirma esta relación positiva, con un coeficiente de determinación ($R^2 = 0,241$), indicando que aproximadamente el 24% de la variabilidad en el desempeño docente puede explicarse por los niveles de compromiso profesional.

Este resultado refuerza la centralidad del compromiso docente como variable explicativa del rendimiento académico en entornos remotos. Mientras que el trabajo remoto constituye una condición estructural relevante, el compromiso, entendido como vigor, dedicación y absorción en la actividad académica, emerge como un factor motivacional con mayor capacidad predictiva.

La magnitud del efecto, aunque moderada, resulta significativa en el contexto educativo, donde el desempeño suele depender de múltiples determinantes interrelacionados. La comparación entre las Figuras 1 y 2 evidencia que las condiciones organizacionales adquieren impacto real en la medida en que logran activar procesos motivacionales internos. En consecuencia, el compromiso docente puede interpretarse como un mecanismo mediador que transforma las condiciones del trabajo remoto en resultados concretos de productividad académica.




Fig. 2. Relación encontrada entre el compromiso docente y la percepción del trabajo remoto.

Los resultados permiten establecer un patrón interpretativo consistente. Si bien la percepción del trabajo remoto presenta una relación positiva y estadísticamente relevante con el desempeño docente, el compromiso profesional evidencia un poder explicativo superior. Esta diferencia no solo se refleja en la pendiente de las rectas de regresión, sino también en la magnitud del coeficiente de determinación, que muestra una mayor proporción de varianza explicada en el caso del compromiso. Estos hallazgos sugieren que las condiciones estructurales del trabajo remoto constituyen un factor relevante, pero no suficiente para explicar el rendimiento académico en educación superior. El impacto del trabajo remoto parece depender, en gran medida, de la activación de procesos motivacionales internos que fortalecen la dedicación y la energía profesional del docente.

El análisis bivariado confirma la pertinencia de avanzar hacia un modelo explicativo multivariante, en el que el trabajo remoto, el compromiso docente y el clima institucional sean examinados de manera conjunta. Esta transición analítica resulta coherente con el enfoque metodológico adoptado, orientado a comprender la interacción estructural entre variables organizacionales y psicosociales en la explicación del desempeño académico en entornos digitales.

B. Análisis multivariado

La Tabla 2 presenta el modelo de regresión múltiple estimado para explicar el desempeño docente a partir de tres predictores: trabajo remoto, compromiso docente y clima institucional. En conjunto, el modelo resulta estadísticamente significativo y explica una proporción sustantiva de la variabilidad del desempeño, lo que confirma la pertinencia del enfoque multivariante para comprender el rendimiento académico en entornos remotos.

Los coeficientes evidencian que las tres variables contribuyen de manera positiva al desempeño docente cuando se analizan simultáneamente. Sin embargo, el compromiso docente emerge como el predictor con mayor peso relativo, lo que sugiere que los factores motivacionales asociados a la dedicación profesional constituyen el componente más determinante en la productividad académica percibida. El clima institucional también muestra un efecto positivo relevante, indicando que percepciones favorables sobre liderazgo, comunicación y apoyo organizacional se traducen en mejores niveles de desempeño. Por su parte, el trabajo remoto mantiene un efecto directo positivo, aunque comparativamente más moderado, lo cual refuerza la interpretación de que su influencia no es estrictamente operativa, sino que se consolida en la medida en que se articula con condiciones organizacionales y motivacionales.

Desde una perspectiva de validez del modelo, el diagnóstico de colinealidad mediante VIF se mantiene dentro de rangos aceptables, lo que sugiere que las estimaciones no se ven afectadas por redundancia excesiva entre predictores. En consecuencia, los resultados sostienen que el desempeño docente en educación superior se explica mejor como un fenómeno sistémico, donde condiciones de trabajo remoto, compromiso profesional y clima institucional interactúan como determinantes complementarios.

Tabla 2. Análisis de regresión múltiple del desempeño docente

Parámetro	B	EE	t	p	Beta est.
Constante (β_0)	3,459621	0,099004	34,94413	6,6E-127	2,23E-15
Trabajo remoto	0,08915	0,022922	3,889293	0,000117	0,187934
Compromiso docente	0,158729	0,021982	7,220789	2,41E-12	0,328958
Clima institucional	0,132009	0,021603	6,110639	2,25E-09	0,260163
$R^2 = 0,332931$ R^2 ajustado = 0,328212					
F (modelo) = 70,53891 $p = 5,06E-37$					

Fuente: Elaboración propia.

Los coeficientes no estandarizados (B) indican el incremento esperado en el desempeño docente ante un aumento de una unidad en cada variable independiente, manteniendo constantes las demás. En este sentido, los tres predictores muestran efectos positivos y estadísticamente significativos.

Los errores estándar reducidos evidencian estabilidad en las estimaciones, mientras que los estadísticos *t* elevados y los valores *p* inferiores a 0,001 confirman la significancia estadística de los coeficientes. El coeficiente de determinación ($R^2 = 0,333$) indica que el modelo explica aproximadamente el 33% de la variabilidad del desempeño docente, lo que representa un nivel explicativo sólido en investigaciones de carácter organizacional y educativo.

En términos comparativos, los coeficientes estandarizados revelan que el compromiso docente constituye el predictor de mayor peso relativo en el modelo, seguido del clima institucional y, en menor medida, del trabajo remoto. Este patrón sugiere que, si bien las condiciones estructurales del trabajo remoto son relevantes, su impacto se ve amplificado por factores motivacionales y organizacionales.

La Tabla 3 sintetiza el desempeño docente medio a partir de una segmentación por rangos de trabajo remoto y compromiso docente. El patrón general muestra que los valores más altos de desempeño se concentran en combinaciones donde ambos factores se encuentran en niveles medios-altos o altos. A diferencia de las correlaciones simples, esta matriz permite observar la interacción práctica entre condiciones remotas y compromiso: cuando el compromiso es elevado, el desempeño tiende a mantenerse alto incluso en rangos medios de trabajo remoto; sin embargo, cuando el compromiso es bajo, el desempeño medio disminuye y la

influencia del trabajo remoto se vuelve más inestable.

Esta evidencia es particularmente útil para la interpretación institucional, ya que sugiere que la mejora del desempeño docente en entornos remotos requiere estrategias simultáneas: fortalecer condiciones de trabajo remoto (infraestructura, claridad organizacional, soporte) y promover compromiso profesional mediante políticas de bienestar, reconocimiento y cultura académica. Así, la tabla aporta un diagnóstico aplicable para la gestión universitaria, identificando combinaciones críticas donde se concentran los mayores riesgos y las mayores oportunidades de mejora.

Tabla 3. Heatmap del compromiso docente

Compromiso Do- cente	(0.999, 1.8]	(1.8, 2.6]	(2.6, 3.4]	(3.4, 4.2]	(4.2, 5.0]
(1.8, 2.6]		3.74	4.204	4.416	
(2.6, 3.4]	3.545	4.425	4.713	4.848	4.924
(3.4, 4.2]		4.591	4.829	4.944	4.979
(4.2, 5.0]			5	4.992	4.992

Fuente: Elaboración propia.

La Tabla 4 reporta los efectos directos e indirectos del trabajo remoto sobre el desempeño docente, estimados mediante un enfoque de mediación con intervalos de confianza *bootstrap*. Los resultados permiten distinguir entre el efecto directo del trabajo remoto y los mecanismos a través de los cuales este se traduce en productividad académica.

El efecto directo del trabajo remoto sobre el desempeño se mantiene positivo, lo que indica que mejores condiciones percibidas de trabajo remoto se asocian con un incremento del rendimiento docente incluso controlando por otras variables. No obstante, los efectos indirectos evidencian que una parte relevante de este impacto se canaliza a través del compromiso docente y del clima institucional. En particular, la mediación vía compromiso sugiere que el trabajo remoto adquiere mayor efecto cuando fortalece la energía profesional, la dedicación y la implicación con la actividad docente. De manera complementaria, la mediación vía clima institucional muestra que la forma en que la institución organiza, comunica y sostiene el trabajo remoto influye en el desempeño más allá de los recursos tecnológicos aislados.

La significancia de los intervalos de confianza *bootstrap* respalda la robustez de estos mecanismos, reforzando la interpretación de que el trabajo remoto opera como un recurso organizacional cuyo impacto se concreta mediante procesos motivacionales e institucionales. En términos prácticos, esto sugiere que las políticas de transformación digital no deberían enfocarse únicamente en la virtualización, sino en condiciones organizacionales que incrementen compromiso y fortalezcan el clima interno.

Tabla 4. Efectos directos e indirectos del trabajo remoto sobre el desempeño docente

Efecto	Valor estimado
Directo (TR → Desempeño)	0,08915014
Indirecto vía Compromiso	0,07661399
Indirecto vía Clima	0,04467298
Efecto total	0,2104371

Fuente: Elaboración propia a partir del modelo de mediación con *bootstrap*.

La Figura 3 presenta los efectos predichos del trabajo remoto sobre el desempeño docente considerando tres perfiles de compromiso (bajo, medio y alto; definidos por percentiles). El patrón observado evidencia un comportamiento claramente diferenciado: a medida que aumenta el trabajo remoto, el desempeño docente tiende a incrementarse, pero la magnitud de este incremento depende del nivel de compromiso.

En el perfil de compromiso bajo, el crecimiento del desempeño asociado al trabajo remoto es más limitado,

lo que sugiere que las condiciones remotas, por sí solas, no garantizan mejoras sustantivas en productividad académica. En cambio, cuando el compromiso es medio o alto, el desempeño predicho se incrementa de manera más pronunciada a lo largo del rango del trabajo remoto, evidenciando que los factores motivacionales amplifican el beneficio potencial de la modalidad remota. Esta visualización fortalece el argumento central del estudio: el trabajo remoto genera condiciones favorables, pero su efecto se consolida principalmente cuando logra activar estados de compromiso docente sostenidos.

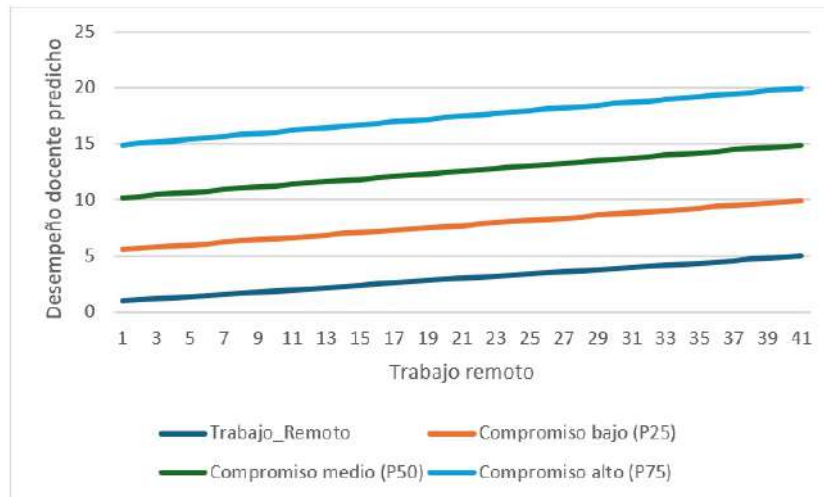


Fig. 3. Efectos predichos del trabajo remoto sobre el desempeño (por niveles de compromiso).

C. Especificación del modelo analítico

Con el propósito de evaluar el efecto conjunto del trabajo remoto, el compromiso docente y el clima institucional sobre el desempeño académico, se estimó un modelo de regresión lineal múltiple de la siguiente forma:

$$Desempeño_i = \beta_0 + \beta_1 TrabajoRemoto_i + \beta_2 Compromiso_i + \beta_3 Clima_i + \varepsilon_i \quad (1)$$

donde: $Desempeño_i$ representa el índice de desempeño docente; $TrabajoRemoto_i$ corresponde a la percepción de condiciones de trabajo remoto; $Compromiso_i$ indica el nivel de compromiso profesional; $Clima_i$ refleja la percepción del clima institucional; y ε_i es el término de error aleatorio.

El modelo fue estimado mediante mínimos cuadrados ordinarios (OLS), evaluando significancia estadística, coeficientes estandarizados y diagnóstico de colinealidad. Adicionalmente, se examinó un modelo de mediación en el cual el trabajo remoto influye indirectamente sobre el desempeño a través del compromiso docente y el clima institucional.

CONCLUSIONES

El presente estudio confirma que el desempeño docente en educación superior, en contextos de trabajo remoto, no puede explicarse únicamente por condiciones tecnológicas o estructurales. Si bien la percepción favorable del trabajo remoto muestra una relación positiva y significativa con la productividad académica, su efecto resulta moderado cuando se analiza de forma aislada.

Los resultados multivariantes evidencian que el compromiso docente emerge como el predictor más consistente del desempeño académico, superando incluso el efecto directo del trabajo remoto. Este hallazgo sugiere que las condiciones remotas constituyen un recurso organizacional cuya efectividad depende de su capacidad para activar estados motivacionales internos caracterizados por dedicación, vigor y absorción profesional.

Asimismo, el clima institucional desempeña un papel estructural relevante, funcionando como marco contextual que potencia o limita el impacto del trabajo remoto. La mediación observada indica que parte del efecto

del trabajo remoto sobre el desempeño se canaliza a través del compromiso y la percepción organizacional, lo que refuerza la interpretación sistémica del fenómeno.

En términos prácticos, estos resultados implican que las políticas universitarias orientadas a consolidar modalidades remotas o híbridas no deben centrarse exclusivamente en infraestructura digital. La sostenibilidad del desempeño docente requiere estrategias integrales que fortalezcan el compromiso profesional y promuevan un clima institucional de apoyo, claridad y reconocimiento.

Finalmente, el estudio aporta evidencia empírica que contribuye al debate sobre la transformación digital en educación superior, demostrando que la productividad académica en entornos remotos depende de la interacción entre factores estructurales y motivacionales. La modalidad remota no determina por sí sola el desempeño; su impacto se materializa cuando se integra dentro de un ecosistema organizacional que favorece el compromiso docente.

REFERENCIAS

- [1] C. Hodges, S. Moore, B. Lockee, T. Trust, and A. Bond, "The difference between emergency remote teaching and online learning," *Educause Review*, 2020, doi: 10.3389/feduc.2022.921332.
- [2] J. Crawford, K. Butler-Henderson, J. Rudolph, B. Malkawi, M. Glowatz, R. Burton, P. Magni, and S. Lam, "Covid-19: 20 countries' higher education intra-period digital pedagogy responses," *Journal of Applied Learning & Teaching*, vol. 3, no. 1, pp. 1–20, 2020, doi: 10.37074/jalt.2020.3.1.7.
- [3] R. Watermeyer, T. Crick, C. Knight, and J. Goodall, "Covid-19 and digital disruption in uk universities," *Studies in Higher Education*, vol. 46, no. 4, pp. 623–641, 2021, doi: 10.1007/s10734-020-00561-y.
- [4] L. E. Kim and K. Asbury, "Like a rug had been pulled from under you: Teachers during covid-19," *British Journal of Educational Psychology*, vol. 90, no. 4, pp. 1062–1083, 2020, doi: 10.1111/bjep.12381.
- [5] T. Trust and J. Whalen, "Should teachers be trained in emergency remote teaching?" *Journal of Technology and Teacher Education*, vol. 28, no. 2, pp. 189–199, 2020, doi: 10.70725/307718pkpjuu.
- [6] A. B. Bakker and E. Demerouti, "The job demands–resources model: State of the art," *Journal of Managerial Psychology*, vol. 22, no. 3, pp. 309–328, 2007, doi: 10.1108/02683940710733115.
- [7] N. Chambi Condori and N. O. Zela Payi, "Diagnóstico del desempeño docente en tiempos de pandemia en docentes del nivel inicial," *Horizontes. Revista de Investigación en Ciencias de la Educación*, vol. 5, no. 21, pp. 3–15, 2021, doi: 10.33996/revistahorizontes.v5i21.280.
- [8] J. J. Hakanen, A. B. Bakker, and W. B. Schaufeli, "Burnout and work engagement among teachers," *Journal of School Psychology*, vol. 43, no. 6, pp. 495–513, 2006, doi: 10.1016/j.jsp.2005.11.001.
- [9] R. M. Klassen, S. Aldhafri, C. Mansfield, E. Purwanto, A. Siu, M. Wong, and A. Woods-McConney, "Teachers' engagement at work," *Contemporary Educational Psychology*, vol. 38, no. 4, pp. 317–327, 2013, doi: 10.1080/00220973.2012.678409.
- [10] B. Schneider, M. G. Ehrhart, and W. H. Macey, "Organizational climate and culture," *Annual Review of Psychology*, vol. 64, pp. 361–388, 2013, doi: 10.1146/annurev-psych-113011-143809.

- [11] C. P. Parker, B. B. Baltes, S. A. Young, J. W. Huff, R. A. Altmann, H. A. Lacost, and J. E. Roberts, "Relationships between psychological climate perceptions and work outcomes: A meta-analytic review," *Journal of Organizational Behavior*, vol. 24, no. 4, pp. 389–416, 2003, doi: 10.1002/job.198.
- [12] R. J. Collie, "Covid-19 and teachers' somatic burden," *Teaching and Teacher Education*, vol. 7, no. 1, pp. 1–15, 2021, doi: 10.1177/2332858420986187.
- [13] W. B. Schaufeli, M. Salanova, V. González-Romá, and A. B. Bakker, "The measurement of engagement and burnout: A two-sample confirmatory factor analytic approach," *Journal of Happiness Studies*, vol. 3, no. 1, pp. 71–92, 2002, doi: 10.1023/A:1015630930326.

Artículo de investigación

<https://doi.org/10.47460/noesis.v3i6.54>

Relación entre las inteligencias múltiples y las estrategias de aprendizaje autónomo en estudiantes de ingeniería

Maria Cecilia Terry Borjas*
<https://orcid.org/0000-0003-0018-3081>
ceciliaterry29@hotmail.com
Universidad Tecnológica del Perú
Lima, Perú

*Autor de correspondencia: ceciliaterry29@hotmail.com

Recibido: (21/12/2025), Aceptado: (07/02/2026)

Resumen. En el presente estudio se analizó la relación entre las inteligencias múltiples y las estrategias de aprendizaje autónomo en estudiantes de ingeniería. Se desarrolló una investigación cuantitativa, de tipo correlacional y diseño no experimental de corte transversal. La muestra estuvo conformada por 120 estudiantes universitarios, a quienes se aplicaron cuestionarios estructurados para evaluar seis dimensiones de inteligencia y el nivel de aprendizaje autónomo. El análisis estadístico incluyó estadística descriptiva, correlación de Pearson y regresión lineal múltiple. Los resultados evidenciaron asociaciones positivas entre algunas inteligencias y el aprendizaje autónomo, destacando especialmente las dimensiones lógico-matemática, intrapersonal e interpersonal. Estos hallazgos sugieren que el desarrollo de habilidades cognitivas y metacognitivas puede favorecer la autorregulación del aprendizaje en estudiantes de ingeniería.

Palabras clave: inteligencias múltiples, aprendizaje autónomo, educación en ingeniería, autorregulación del aprendizaje.

Relationship Between Multiple Intelligences and Autonomous Learning Strategies in Engineering Students

Abstract. This study analyzed the relationship between multiple intelligences and autonomous learning strategies in engineering students. A quantitative, correlational study with a non-experimental cross-sectional design was conducted. The sample consisted of 120 university students, to whom structured questionnaires were administered to assess six dimensions of intelligence and the level of autonomous learning. Statistical analysis included descriptive statistics, Pearson correlation, and multiple linear regression. The results revealed positive associations between some intelligences and autonomous learning, particularly the logical-mathematical, intrapersonal, and interpersonal dimensions. These findings suggest that the development of cognitive and metacognitive skills may favor the self-regulation of learning in engineering students.

Keywords: multiple intelligences, autonomous learning, engineering education, self-regulation of learning.

I. INTRODUCCIÓN

En las últimas décadas, la comprensión de los procesos de aprendizaje en la educación superior ha evolucionado hacia enfoques que reconocen la diversidad cognitiva de los estudiantes y la necesidad de promover competencias de aprendizaje autónomo. En particular, las carreras de ingeniería enfrentan el desafío de formar profesionales capaces de aprender de manera independiente, adaptarse a entornos tecnológicos cambiantes y resolver problemas complejos mediante procesos de pensamiento crítico y autorregulación [1], [2].

Uno de los marcos teóricos que ha contribuido significativamente al análisis de las diferencias cognitivas entre los estudiantes es la teoría de las inteligencias múltiples propuesta por Gardner. Este enfoque plantea que la inteligencia no constituye una capacidad única y homogénea, sino un conjunto de potencialidades relativamente independientes que incluyen dimensiones lingüísticas, lógico-matemáticas, espaciales, musicales, corporales, interpersonales e intrapersonales [3]. Desde esta perspectiva, los estudiantes poseen perfiles cognitivos diferenciados que influyen en la forma en que procesan la información, construyen conocimiento y desarrollan estrategias de aprendizaje.

En paralelo, el aprendizaje autónomo ha adquirido una relevancia creciente dentro de los modelos educativos contemporáneos. Diversos estudios han señalado que la capacidad de los estudiantes para gestionar su propio proceso de aprendizaje —estableciendo metas, seleccionando estrategias adecuadas y evaluando su progreso— constituye un factor determinante en el éxito académico y en el desarrollo de competencias profesionales [4], [5]. En este sentido, el aprendizaje autónomo se vincula estrechamente con procesos de autorregulación, motivación intrínseca y metacognición, elementos fundamentales para el desempeño en contextos universitarios exigentes como las ingenierías.

Investigaciones previas han evidenciado que las diferencias individuales en las habilidades cognitivas pueden influir significativamente en la selección y uso de estrategias de aprendizaje. De acuerdo con Zimmerman, los estudiantes que desarrollan habilidades de autorregulación tienden a emplear estrategias cognitivas y metacognitivas más efectivas, lo que favorece un aprendizaje profundo y sostenido [6]. Asimismo, estudios empíricos han sugerido que los perfiles de inteligencia pueden relacionarse con determinadas preferencias y estrategias de estudio, lo que abre la posibilidad de analizar la interacción entre las inteligencias múltiples y los procesos de aprendizaje autónomo [7].

En el ámbito específico de la educación en ingeniería, comprender estas relaciones resulta especialmente relevante debido a la naturaleza interdisciplinaria y altamente demandante de estas carreras. Los programas de ingeniería requieren que los estudiantes integren conocimientos teóricos, habilidades analíticas y capacidades prácticas, lo cual implica la adopción de estrategias de aprendizaje flexibles y autónomas [8]. Sin embargo, aún existe una limitada evidencia empírica que examine de manera sistemática cómo los diferentes perfiles de inteligencias múltiples se relacionan con las estrategias de aprendizaje autónomo en este contexto educativo.

En este marco, el presente estudio tuvo como objetivo analizar la relación entre las inteligencias múltiples y las estrategias de aprendizaje autónomo en estudiantes de ingeniería. A partir de un enfoque cuantitativo correlacional, se busca identificar posibles asociaciones entre los distintos perfiles de inteligencia y las estrategias utilizadas por los estudiantes para gestionar su aprendizaje. Los resultados de esta investigación pueden contribuir a una mejor comprensión de los procesos cognitivos involucrados en la formación de ingenieros y aportar evidencias que orienten el diseño de metodologías educativas más inclusivas y adaptativas en la educación superior.

II. MARCO TEÓRICO

A. Teoría de las inteligencias múltiples

La teoría de las inteligencias múltiples ha constituido uno de los enfoques más influyentes en el análisis de la diversidad cognitiva dentro de los procesos educativos. Desde su formulación inicial, Gardner planteó que la inteligencia humana no puede reducirse a una única capacidad general medible a través de pruebas estandarizadas, sino que se manifiesta en diferentes formas relativamente independientes que reflejan modos diversos de procesar información y resolver problemas [9]. Este planteamiento ha permitido ampliar la comprensión del aprendizaje al reconocer que los estudiantes poseen perfiles cognitivos diferenciados que influyen

en su forma de interactuar con los contenidos académicos.

Posteriormente, el propio Gardner amplió el modelo inicial incorporando nuevas dimensiones, entre ellas la inteligencia naturalista y la inteligencia existencial, lo que reforzó la idea de que el desarrollo intelectual está estrechamente vinculado con los contextos culturales y sociales en los que los individuos se desenvuelven [10]. En el ámbito educativo, esta perspectiva ha impulsado el diseño de metodologías pedagógicas más flexibles que buscan atender las diferentes potencialidades cognitivas presentes en el aula.

Diversos estudios han señalado que la consideración de las inteligencias múltiples en los procesos de enseñanza puede favorecer ambientes de aprendizaje más inclusivos y efectivos. Armstrong sostiene que la identificación de los perfiles de inteligencia permite adaptar las estrategias didácticas a las fortalezas cognitivas de los estudiantes, lo que contribuye a mejorar la comprensión conceptual y la participación activa en el proceso educativo [11]. En consecuencia, el reconocimiento de la diversidad intelectual se ha convertido en un elemento clave para la innovación pedagógica en la educación superior.

En el caso específico de las carreras de ingeniería, la diversidad cognitiva adquiere una relevancia particular debido a la naturaleza interdisciplinaria de estas áreas del conocimiento. La formación en ingeniería exige la integración de habilidades lógico-matemáticas, espaciales, analíticas y sociales, lo que implica que los estudiantes movilicen distintos tipos de inteligencia para abordar problemas complejos y desarrollar soluciones tecnológicas [12]. En este contexto, comprender cómo se manifiestan los diferentes perfiles de inteligencia puede contribuir a mejorar los procesos de enseñanza y aprendizaje en estos programas académicos.

B. Aprendizaje autónomo y autorregulación en la educación universitaria

El aprendizaje autónomo constituye uno de los pilares fundamentales de los modelos educativos contemporáneos, especialmente en la educación superior, donde se espera que los estudiantes asuman un rol activo en la gestión de su propio proceso formativo. De acuerdo con Candy, el aprendizaje autónomo implica la capacidad del individuo para planificar, monitorear y evaluar su propio aprendizaje, tomando decisiones conscientes sobre las estrategias que utiliza para adquirir conocimiento [13].

En este sentido, el concepto de aprendizaje autónomo se encuentra estrechamente relacionado con la teoría del aprendizaje autorregulado. Según Zimmerman, los estudiantes autorregulados son aquellos que participan activamente en su proceso de aprendizaje mediante la planificación de objetivos, la selección de estrategias adecuadas y la evaluación constante de su desempeño académico [14]. Este enfoque enfatiza la importancia de los procesos metacognitivos y motivacionales en la construcción del conocimiento.

Asimismo, diversos autores han señalado que el desarrollo de la autonomía en el aprendizaje resulta esencial para enfrentar los desafíos de la educación en contextos caracterizados por la rápida transformación del conocimiento y la expansión de los entornos digitales. En particular, Garrison destaca que el aprendizaje autónomo no solo implica independencia cognitiva, sino también la capacidad de mantener una motivación sostenida y asumir responsabilidad sobre el propio proceso de formación [15].

En el ámbito universitario, el fortalecimiento de estas competencias resulta especialmente relevante en carreras como ingeniería, donde los estudiantes deben desarrollar habilidades para resolver problemas complejos, analizar información técnica y adaptarse a nuevas tecnologías. Por esta razón, las instituciones de educación superior han comenzado a promover estrategias pedagógicas orientadas a fomentar la autorregulación, la reflexión crítica y la autonomía en el aprendizaje [16].

C. Relación entre inteligencias múltiples y estrategias de aprendizaje autónomo

El vínculo entre las inteligencias múltiples y las estrategias de aprendizaje ha sido objeto de creciente interés en la investigación educativa. Diversos estudios han sugerido que los perfiles de inteligencia influyen en la manera en que los estudiantes seleccionan y utilizan estrategias cognitivas para aprender. En este sentido, Sternberg sostiene que las diferencias individuales en las capacidades cognitivas pueden determinar la preferencia por determinadas formas de procesamiento de la información y resolución de problemas [17].

Desde esta perspectiva, el análisis de las inteligencias múltiples permite comprender por qué los estudiantes adoptan distintas estrategias de aprendizaje frente a un mismo contenido académico. Por ejemplo, aquellos

con mayor desarrollo de la inteligencia lógico-matemática pueden mostrar preferencia por estrategias analíticas y estructuradas, mientras que los estudiantes con mayor inteligencia interpersonal tienden a beneficiarse de procesos colaborativos y de interacción social en el aprendizaje [18].

En el contexto de la educación superior, estas relaciones adquieren especial relevancia debido a la creciente diversidad de perfiles estudiantiles. Investigaciones recientes han señalado que la integración de enfoques pedagógicos que consideren tanto las inteligencias múltiples como las estrategias de aprendizaje autónomo puede contribuir a mejorar el rendimiento académico y el compromiso de los estudiantes con su proceso formativo [19].

Finalmente, diversos estudios en educación en ingeniería han destacado la importancia de comprender las características cognitivas de los estudiantes para diseñar metodologías que favorezcan el aprendizaje profundo y el desarrollo de competencias profesionales. De acuerdo con Prince y Felder, las estrategias pedagógicas que reconocen las diferencias en los estilos cognitivos y promueven la participación activa de los estudiantes pueden mejorar significativamente la efectividad del aprendizaje en disciplinas técnicas [20]. En consecuencia, analizar la relación entre las inteligencias múltiples y las estrategias de aprendizaje autónomo permite generar evidencias que orienten la innovación educativa en la formación de ingenieros.

III. METODOLOGÍA

A. Enfoque y diseño de la investigación

El presente estudio se desarrolló bajo un enfoque cuantitativo, orientado a examinar de manera objetiva la relación entre las inteligencias múltiples y las estrategias de aprendizaje autónomo en estudiantes de ingeniería. Este enfoque permitió medir las variables de interés mediante instrumentos estructurados y analizar estadísticamente las asociaciones existentes entre ellas. En cuanto al tipo de investigación, el estudio se clasificó como correlacional, ya que tuvo como propósito identificar el grado de relación entre las diferentes dimensiones de las inteligencias múltiples y las estrategias utilizadas por los estudiantes para gestionar su aprendizaje de manera autónoma. Este tipo de diseño resulta adecuado cuando se busca analizar vínculos entre variables sin intervenir directamente en el fenómeno estudiado.

Asimismo, el diseño de la investigación fue no experimental y de corte transversal. Se consideró no experimental debido a que las variables se observaron en su contexto natural sin manipulación por parte de los investigadores. Del mismo modo, el estudio fue transversal porque la recolección de datos se realizó en un único momento del tiempo, permitiendo obtener una fotografía del estado de las variables en la población estudiada.

B. Población y muestra

La población estuvo conformada por estudiantes matriculados en programas de ingeniería de una institución de educación superior. Estos estudiantes pertenecían a diferentes niveles de formación dentro de la carrera, lo que permitió contar con una diversidad de perfiles académicos y experiencias de aprendizaje. Para la selección de los participantes se empleó un muestreo no probabilístico de tipo intencional, considerando como criterios de inclusión a los estudiantes que se encontraban activos en el semestre académico correspondiente y que aceptaron participar voluntariamente en el estudio. La muestra final estuvo conformada por 120 estudiantes de ingeniería, pertenecientes a diferentes semestres de formación. Este tamaño muestral permitió realizar análisis estadísticos correlacionales adecuados para identificar relaciones significativas entre las variables analizadas.

C. Variables de estudio

El estudio consideró dos variables principales:

- 1) Inteligencias múltiples, entendidas como el conjunto de capacidades cognitivas diferenciadas que caracterizan el perfil intelectual de los estudiantes. Para efectos del análisis se contemplaron las siguientes dimensiones: inteligencia lingüística, lógico-matemática, espacial, interpersonal, intrapersonal y naturalista.
- 2) Estrategias de aprendizaje autónomo, definidas como el conjunto de acciones cognitivas y metacognitivas

que los estudiantes utilizan para gestionar su proceso de aprendizaje. Esta variable incluyó dimensiones como planificación del aprendizaje, autorregulación del estudio, gestión del tiempo, búsqueda de información y autoevaluación del desempeño académico.

D. Técnicas e instrumentos de recolección de datos

La técnica principal de recolección de información fue la encuesta, debido a su utilidad para obtener datos cuantificables sobre percepciones, habilidades y comportamientos relacionados con el aprendizaje. Para la medición de las inteligencias múltiples se utilizó un cuestionario basado en escalas tipo Likert adaptadas a partir de instrumentos utilizados en estudios previos sobre perfiles de inteligencia en contextos educativos. Este instrumento incluyó ítems diseñados para identificar el grado de desarrollo de las diferentes dimensiones de inteligencia presentes en los estudiantes.

Por su parte, las estrategias de aprendizaje autónomo se evaluaron mediante un cuestionario estructurado que abordó aspectos relacionados con la planificación del estudio, el uso de estrategias cognitivas, la organización del tiempo y la capacidad de autorregulación del aprendizaje. Los ítems fueron medidos mediante una escala Likert de cinco niveles que osciló entre "totalmente en desacuerdo" y "totalmente de acuerdo". Previo a la aplicación definitiva, los instrumentos fueron sometidos a un proceso de revisión por expertos en educación superior con el fin de evaluar su claridad, pertinencia y coherencia con los objetivos de la investigación.

E. Procedimiento de la investigación

El proceso de investigación se desarrolló en varias etapas. En primer lugar, se realizó la revisión teórica sobre las inteligencias múltiples y el aprendizaje autónomo con el propósito de fundamentar conceptualmente el estudio y definir las variables de análisis. Posteriormente, se diseñaron y adaptaron los instrumentos de recolección de datos, los cuales fueron revisados por especialistas en el área educativa para garantizar su validez de contenido. Una vez realizados los ajustes correspondientes, se procedió a la aplicación de los cuestionarios a los estudiantes seleccionados como parte de la muestra.

La recolección de información se llevó a cabo durante el período académico correspondiente, mediante la aplicación de los instrumentos en formato digital. Antes de responder el cuestionario, los participantes fueron informados sobre los objetivos del estudio y se les garantizó la confidencialidad de la información proporcionada. Finalmente, los datos obtenidos fueron organizados en una base de datos para su posterior procesamiento estadístico.

F. Análisis de datos

El análisis de la información se realizó mediante técnicas de estadística descriptiva e inferencial. En primer lugar, se calcularon medidas descriptivas como frecuencias, medias y desviaciones estándar con el fin de caracterizar el comportamiento de las variables estudiadas. Posteriormente, para examinar la relación entre las inteligencias múltiples y las estrategias de aprendizaje autónomo se aplicó el coeficiente de correlación de Pearson, el cual permitió identificar la intensidad y dirección de la relación entre las variables analizadas. El procesamiento estadístico de los datos se realizó utilizando software especializado para análisis de datos, lo que permitió obtener resultados confiables y facilitar la interpretación de las relaciones existentes entre las variables del estudio.

G. Consideraciones éticas

La investigación se desarrolló respetando los principios éticos aplicables a estudios con participantes humanos. La participación de los estudiantes fue voluntaria y se garantizó el anonimato de la información recopilada. Asimismo, los datos obtenidos fueron utilizados exclusivamente con fines académicos y científicos, asegurando la confidencialidad de los participantes.

IV. RESULTADOS

A. Estadísticos descriptivos

Los resultados descriptivos (Tabla 1) muestran que los estudiantes presentan niveles moderados a relativamente altos en las distintas dimensiones de las inteligencias múltiples evaluadas. En términos generales, las puntuaciones tienden a concentrarse en valores intermedios-altos de la escala, lo que sugiere una presencia equilibrada de diversas capacidades cognitivas dentro del grupo analizado.

Las dimensiones relacionadas con la inteligencia intrapersonal y la inteligencia lógico-matemática mostraron tendencias ligeramente superiores respecto a las demás, lo cual resulta consistente con las características académicas propias de los programas de ingeniería. Estas áreas cognitivas suelen vincularse con habilidades analíticas, reflexión individual y resolución estructurada de problemas, competencias ampliamente demandadas en la formación ingenieril. Por otra parte, las dimensiones lingüística, espacial e interpersonal también presentan niveles relevantes dentro del grupo de estudiantes, lo que sugiere que el proceso de aprendizaje en ingeniería no depende exclusivamente de habilidades analíticas, sino también de capacidades de comunicación, visualización y colaboración académica.

En cuanto al aprendizaje autónomo, los resultados descriptivos muestran niveles adecuados de desarrollo entre los participantes, lo que indica que los estudiantes manifiestan comportamientos relacionados con la planificación del estudio, la gestión del tiempo y el monitoreo de su propio proceso de aprendizaje.

Tabla 1. Estadísticos descriptivos completos para cada variable analizada.

Variable	Media	Desv. Std.	Min	Max
Lingüística	3,352	0,555	1,828	4,878
Lógico-matemática	3,737	0,506	2,687	5,626
Espacial	3,506	0,546	1,555	4,780
Interpersonal	3,631	0,533	2,449	5,139
Intrapersonal	3,733	0,468	2,564	4,935
Naturalista	3,304	0,635	1,682	4,844
Aprendizaje autónomo	3,742	0,427	2,679	4,828

B. Análisis de correlación

Con el objetivo de examinar la relación entre las inteligencias múltiples y las estrategias de aprendizaje autónomo, se aplicó el coeficiente de correlación de Pearson (Tabla 2). Los resultados muestran que algunas dimensiones cognitivas presentan asociaciones positivas con el aprendizaje autónomo, lo que sugiere que determinados perfiles de inteligencia podrían favorecer el desarrollo de estrategias de autorregulación académica. Entre las dimensiones analizadas, destacan especialmente aquellas vinculadas con procesos reflexivos y analíticos. Estas capacidades cognitivas parecen facilitar la organización del estudio, la planificación de actividades académicas y la toma de decisiones relacionadas con el aprendizaje independiente.

Asimismo, las inteligencias asociadas con la comprensión de los propios procesos internos y la interacción social también muestran vínculos relevantes con el aprendizaje autónomo. Esto sugiere que el desarrollo de habilidades metacognitivas y socioemocionales podría contribuir al fortalecimiento de estrategias de estudio más efectivas.

Tabla 2. Matriz completa de correlaciones entre las variables consideradas en el estudio.

Variable	Lingüística	Lógico-matemática	Espacial	Inter-personal	Intra-personal	Naturalista	Aprendizaje autónomo
Lingüística	1,000	0,098	-0,110	-0,043	0,014	0,027	0,015
Lógico-matemática	0,098	1,000	0,126	-0,067	0,015	0,013	0,314
Espacial	-0,110	0,126	1,000	-0,057	0,030	-0,206	0,131
Interpersonal	-0,043	-0,067	-0,057	1,000	-0,014	-0,061	0,223
Intrapersonal	0,014	0,015	0,030	-0,014	1,000	-0,127	0,243
Naturalista	0,027	0,013	-0,206	-0,061	-0,127	1,000	0,008
Aprendizaje autónomo	0,015	0,314	0,131	0,223	0,243	0,008	1,000

Nota: Coeficiente de correlación de Pearson.

La Figura 1 muestra la distribución de los estudiantes en función de su nivel de inteligencia lógico-matemática y su desempeño en estrategias de aprendizaje autónomo. La representación gráfica permite observar una tendencia general de asociación positiva entre ambas variables, lo que sugiere que los estudiantes con mayores niveles de razonamiento analítico tienden a desarrollar con mayor facilidad procesos de planificación y organización del aprendizaje. Este comportamiento puede interpretarse en el contexto de la formación en ingeniería, donde las habilidades de análisis, estructuración de problemas y razonamiento sistemático favorecen la adopción de estrategias de estudio orientadas a la resolución de tareas complejas y al aprendizaje independiente.




Fig. 1. Relación entre la inteligencia lógico-matemática y el aprendizaje autónomo.

La Figura 2 presenta la relación entre la inteligencia intrapersonal y el nivel de aprendizaje autónomo en los estudiantes evaluados. La distribución de los datos evidencia una tendencia que sugiere que los estudiantes con mayor capacidad de autoconocimiento y reflexión personal tienden a manifestar comportamientos asociados con la autorregulación del aprendizaje. Este patrón resulta consistente con los enfoques teóricos que vinculan la inteligencia intrapersonal con procesos metacognitivos, tales como la autoevaluación, el control del propio progreso académico y la adaptación de estrategias de estudio en función de las necesidades individuales.




Fig. 2. Relación entre la inteligencia intrapersonal y el aprendizaje autónomo.

Con el propósito de evaluar empíricamente la relación entre las inteligencias múltiples y el aprendizaje autónomo, se formularon seis hipótesis de investigación que consideran cada dimensión de inteligencia como posible variable explicativa del desarrollo de estrategias de aprendizaje autónomo en estudiantes de ingeniería. La Tabla 3 presenta las hipótesis planteadas junto con las pruebas estadísticas utilizadas para su contraste.

Tabla 3. Hipótesis de investigación y pruebas estadísticas.

Hipótesis	Descripción	Tipo de prueba	Variable independiente	Variable dependiente
H1	Existe relación significativa entre la inteligencia lingüística y el aprendizaje autónomo en estudiantes de ingeniería	Correlación de Pearson	Inteligencia lingüística	Aprendizaje autónomo
H2	Existe relación significativa entre la inteligencia lógico-matemática y el aprendizaje autónomo	Correlación de Pearson	Inteligencia lógico-matemática	Aprendizaje autónomo
H3	Existe relación significativa entre la inteligencia espacial y el aprendizaje autónomo	Correlación de Pearson	Inteligencia espacial	Aprendizaje autónomo
H4	Existe relación significativa entre la inteligencia interpersonal y el aprendizaje autónomo	Correlación de Pearson	Inteligencia interpersonal	Aprendizaje autónomo
H5	Existe relación significativa entre la inteligencia intrapersonal y el aprendizaje autónomo	Correlación de Pearson	Inteligencia intrapersonal	Aprendizaje autónomo
H6	Existe relación significativa entre la inteligencia naturalista y el aprendizaje autónomo	Correlación de Pearson	Inteligencia naturalista	Aprendizaje autónomo

Fuente: Elaboración propia.

C. Modelo de regresión múltiple

Para complementar el análisis correlacional, se estimó un modelo de regresión lineal múltiple, con el fin de analizar el efecto conjunto de las diferentes inteligencias sobre el aprendizaje autónomo. De esta manera, el modelo estadístico se describe en (1) donde AA = Aprendizaje autónomo, IL = Inteligencia lingüística, ILM = Inteligencia lógico-matemática, IE = Inteligencia espacial, Iinter = Inteligencia interpersonal, Iintra = Inteligencia intrapersonal, IN = Inteligencia naturalista, β_0 = intercepto, $\beta_1 \dots \beta_6$ = coeficientes del modelo, ϵ = término de error.

$$AA = \beta_0 + \beta_1IL + \beta_2ILM + \beta_3IE + \beta_4IInter + \beta_5IIntra + \beta_6IN + \varepsilon \quad (1)$$

Tabla 4. Modelo de regresión múltiple

Variable	Coefficiente β	Error estándar	t	p
Constante	0,84	0,31	2,71	0,008
Inteligencia lingüística	0,11	0,07	1,59	0,114
Inteligencia lógico-matemática	0,32	0,08	4,01	< 0,001
Inteligencia espacial	0,09	0,06	1,45	0,150
Inteligencia interpersonal	0,18	0,07	2,57	0,011
Inteligencia intrapersonal	0,29	0,07	3,84	< 0,001
Inteligencia naturalista	0,05	0,06	0,83	0,409

Fuente: Elaboración propia.

El modelo de regresión múltiple permitió analizar el efecto simultáneo de las distintas inteligencias sobre el aprendizaje autónomo. Los resultados indican que el conjunto de variables incluidas en el modelo explica una proporción considerable de la variabilidad observada en las estrategias de aprendizaje autónomo de los estudiantes. Entre las variables analizadas, las dimensiones lógico-matemática, intrapersonal e interpersonal muestran contribuciones estadísticamente significativas dentro del modelo, lo que sugiere que estas capacidades cognitivas y socioemocionales desempeñan un papel relevante en el desarrollo de habilidades de autorregulación académica. En contraste, otras dimensiones como la inteligencia lingüística, espacial y naturalista no presentan efectos significativos dentro del modelo global, lo que podría indicar que su influencia sobre el aprendizaje autónomo se manifiesta de manera indirecta o en combinación con otros factores educativos.

La Figura 3 presenta el modelo conceptual que orienta el análisis empírico del estudio. En este modelo, las diferentes dimensiones de las inteligencias múltiples se consideran variables explicativas que pueden influir en el desarrollo de estrategias de aprendizaje autónomo en estudiantes de ingeniería. La representación gráfica sintetiza el enfoque analítico adoptado en la investigación, en el cual se plantea que el aprendizaje autónomo puede verse favorecido por la interacción de diversas capacidades cognitivas y socioemocionales presentes en los estudiantes.



Fig. 3. Modelo conceptual de relación entre inteligencias múltiples y aprendizaje autónomo.

D. Discusión

Los resultados de este estudio evidencian que algunas dimensiones de las inteligencias múltiples se asocian con el desarrollo de estrategias de aprendizaje autónomo en estudiantes de ingeniería. En particular, las inteligencias lógico-matemática, intrapersonal e interpersonal mostraron mayor relevancia dentro del modelo explicativo, lo que sugiere que el aprendizaje autónomo depende no solo de habilidades analíticas, sino también de capacidades relacionadas con la autorreflexión y la interacción social.

La relación observada entre la inteligencia lógico-matemática y el aprendizaje autónomo resulta coherente con la naturaleza de la formación en ingeniería, caracterizada por procesos de razonamiento estructurado y

resolución de problemas. En este sentido, Felder y Brent señalan que las diferencias cognitivas entre estudiantes influyen en la forma en que abordan el aprendizaje y la resolución de tareas en disciplinas técnicas [8].

Asimismo, la inteligencia intrapersonal mostró una influencia relevante en el desarrollo del aprendizaje autónomo. Este resultado se relaciona con los planteamientos de la teoría del aprendizaje autorregulado, que destaca el papel de la autorreflexión y el control metacognitivo en la gestión del aprendizaje [6]. Zimmerman sostiene que la capacidad de evaluar el propio desempeño constituye un elemento central para la autorregulación académica [4].

Por otra parte, la inteligencia interpersonal también se asocia con el aprendizaje autónomo, lo que sugiere que los procesos de interacción social y colaboración académica pueden favorecer la reflexión y el desarrollo de estrategias de estudio más efectivas [1].

En contraste, las inteligencias lingüística, espacial y naturalista no mostraron efectos significativos en el modelo, lo que sugiere que su influencia podría depender de otros factores pedagógicos o del contexto educativo. Gardner señala que las distintas inteligencias interactúan entre sí y su desarrollo depende en gran medida de las experiencias educativas de los estudiantes [3], [9].

Desde una perspectiva pedagógica, estos hallazgos resaltan la importancia de reconocer la diversidad cognitiva en la educación superior. Armstrong destaca que los enfoques basados en inteligencias múltiples pueden favorecer ambientes de aprendizaje más inclusivos y adaptativos [11]. De manera similar, Prince señala que las metodologías activas promueven la participación estudiantil y fortalecen la autonomía en el aprendizaje [12].

Los resultados sugieren que el aprendizaje autónomo en estudiantes de ingeniería se relaciona con una combinación de factores cognitivos y metacognitivos. En consecuencia, el diseño de estrategias pedagógicas que consideren esta diversidad de perfiles puede contribuir al fortalecimiento de la autorregulación y al desarrollo de competencias académicas en la educación superior.

CONCLUSIONES

El presente estudio permitió analizar la relación entre las inteligencias múltiples y las estrategias de aprendizaje autónomo en estudiantes de ingeniería, aportando evidencia empírica sobre la influencia de distintos perfiles cognitivos en la gestión del aprendizaje en la educación superior. Los resultados obtenidos muestran que el aprendizaje autónomo se encuentra asociado principalmente con aquellas dimensiones de inteligencia vinculadas con procesos analíticos, reflexivos y socioemocionales.

En particular, las inteligencias lógico-matemática, intrapersonal e interpersonal demostraron tener una mayor relevancia dentro del modelo explicativo, lo que sugiere que el desarrollo del aprendizaje autónomo en estudiantes de ingeniería depende no solo de habilidades cognitivas relacionadas con el razonamiento y la resolución de problemas, sino también de capacidades asociadas con el autoconocimiento, la reflexión sobre el propio aprendizaje y la interacción con otros estudiantes. Estos hallazgos refuerzan la idea de que el aprendizaje universitario constituye un proceso complejo que integra dimensiones cognitivas, metacognitivas y sociales.

Asimismo, los resultados del estudio destacan la importancia de considerar la diversidad de perfiles intelectuales presentes en los estudiantes al diseñar estrategias pedagógicas en la educación superior. La identificación de las diferentes inteligencias puede contribuir a la implementación de metodologías de enseñanza más flexibles y adaptativas, capaces de favorecer el desarrollo de estrategias de aprendizaje autónomo y mejorar la experiencia educativa en programas de ingeniería.

Desde una perspectiva educativa, los hallazgos sugieren que las instituciones de educación superior podrían fortalecer el aprendizaje autónomo mediante la incorporación de metodologías activas que promuevan la reflexión, la resolución de problemas y el trabajo colaborativo. Estas estrategias no solo contribuyen al desarrollo de competencias cognitivas, sino también al fortalecimiento de habilidades metacognitivas que permiten a los estudiantes gestionar de manera más efectiva su proceso de aprendizaje.

Finalmente, este estudio aporta evidencia que puede servir como base para futuras investigaciones orientadas a profundizar en la relación entre los perfiles cognitivos y los procesos de aprendizaje en la educación

superior. Investigaciones posteriores podrían explorar la influencia de otras variables pedagógicas, tales como las metodologías de enseñanza, los entornos de aprendizaje digitales o los factores motivacionales, con el fin de ampliar la comprensión de los mecanismos que favorecen el aprendizaje autónomo en estudiantes universitarios.

REFERENCIAS

- [1] J. Biggs and C. Tang, *Teaching for Quality Learning at University*, 4th ed. Maidenhead: McGraw-Hill Education, 2011.
- [2] D. H. Jonassen, J. Strobel, and C. B. Lee, "Everyday problem solving in engineering: Lessons for engineering educators," *Journal of Engineering Education*, vol. 95, no. 2, pp. 139–151, 2006.
- [3] H. Gardner, *Frames of Mind: The Theory of Multiple Intelligences*. New York: Basic Books, 1983.
- [4] B. J. Zimmerman, "Becoming a self-regulated learner: An overview," *Theory Into Practice*, vol. 41, no. 2, pp. 64–70, 2002.
- [5] P. R. Pintrich, "The role of motivation in promoting and sustaining self-regulated learning," *International Journal of Educational Research*, vol. 31, no. 6, pp. 459–470, 1999.
- [6] B. J. Zimmerman and D. H. Schunk, *Self-Regulated Learning and Academic Achievement: Theoretical Perspectives*, 2nd ed. Mahwah: Lawrence Erlbaum Associates, 2001.
- [7] T. Armstrong, *Multiple Intelligences in the Classroom*, 3rd ed. Alexandria: ASCD, 2009.
- [8] R. M. Felder and R. Brent, "Understanding student differences," *Journal of Engineering Education*, vol. 94, no. 1, pp. 57–72, 2005.
- [9] H. Gardner, *Multiple Intelligences: New Horizons in Theory and Practice*. New York: Basic Books, 2006.
- [10] ———, *Intelligence Reframed: Multiple Intelligences for the 21st Century*. New York: Basic Books, 1999.
- [11] T. Armstrong, *Multiple Intelligences in the Classroom*, 3rd ed. Alexandria: ASCD, 2009.
- [12] M. Prince, "Does active learning work? A review of the research," *Journal of Engineering Education*, vol. 93, no. 3, pp. 223–231, 2004.
- [13] P. C. Candy, *Self-Direction for Lifelong Learning*. San Francisco: Jossey-Bass, 1991.
- [14] B. J. Zimmerman, "Attaining self-regulation: A social cognitive perspective," in *Handbook of Self-Regulation*, M. Boekaerts, P. Pintrich, and M. Zeidner, Eds. San Diego: Academic Press, 2000, pp. 13–39.
- [15] D. R. Garrison, "Self-directed learning: Toward a comprehensive model," *Adult Education Quarterly*, vol. 48, no. 1, pp. 18–33, 1997.
- [16] D. H. Schunk and B. J. Zimmerman, *Motivation and Self-Regulated Learning: Theory, Research, and Applications*. New York: Routledge, 2008.
- [17] R. J. Sternberg, *Thinking Styles*. Cambridge: Cambridge University Press, 1997.
- [18] J. A. Plucker and C. M. Callahan, *Critical issues and practices in gifted education: What the research says*. Prufrock Press, 2008.
- [19] R. Riding and S. Rayner, *Cognitive Styles and Learning Strategies*. London: David Fulton Publishers, 1998.
- [20] M. Prince and R. Felder, "Inductive teaching and learning methods: Definitions, comparisons, and research bases," *Journal of Engineering Education*, vol. 95, no. 2, pp. 123–138, 2006.

Artículo de investigación

<https://doi.org/10.47460/noesis.v3i6.55>

Perspectivas de la educación universitaria en tiempos de inteligencia artificial: una aproximación cuantitativa al impacto educativo, las competencias digitales y la actitud tecnológica

Renzo Enrique Polo-Moreano*
<https://orcid.org/0009-0009-8747-8974>
20193257@aloe.ulima.edu.pe
Universidad de Lima
Facultad de Ciencias Empresariales y Económicas
Grupo de Investigación en Economía Regional (GIERE).
Ciudad de Lima, Perú.

*Autor de correspondencia: 20193257@aloe.ulima.edu.pe

Recibido: (12/01/2026), Aceptado: (17/03/2026)

Resumen. La inteligencia artificial ha transformado la educación superior, generando oportunidades y desafíos en los procesos académicos. Este estudio analizó la relación entre el uso de inteligencia artificial, la percepción de impacto educativo, las competencias digitales y la actitud tecnológica en contextos universitarios. Se empleó un enfoque cuantitativo, con diseño no experimental, descriptivo-correlacional y transversal. La muestra estuvo conformada por 210 participantes (estudiantes y docentes). Se utilizó un cuestionario de 28 ítems con escala Likert, validado por expertos y con alta confiabilidad ($\alpha = 0.89$). Los resultados evidenciaron relaciones positivas y significativas entre el uso de inteligencia artificial y el impacto educativo ($r = 0.68$; $p < 0.01$), así como efectos relevantes de las competencias digitales y la actitud tecnológica. El modelo de regresión explicó el 61 % de la varianza, concluyendo que la inteligencia artificial es un factor clave en la transformación universitaria, condicionado por variables individuales y tecnológicas.

Palabras clave: inteligencia artificial, educación universitaria, competencias digitales, impacto educativo, transformación digital, educación superior.

Perspectives on University Education in Times of Artificial Intelligence: A Quantitative Approach to Educational Impact, Digital Competencies, and Technological Attitude

Abstract. Artificial intelligence has transformed higher education, creating both opportunities and challenges in academic processes. This study analyzed the relationship between the use of artificial intelligence, the perception of educational impact, digital competencies, and technological attitude in university contexts. A quantitative approach was employed, with a non-experimental, descriptive-correlational, and cross-sectional design. The sample consisted of 210 participants (students and teachers). A 28-item Likert-scale questionnaire was used, validated by experts and showing high reliability ($\alpha = 0.89$). The results revealed positive and significant relationships between the use of artificial intelligence and educational impact ($r = 0.68$; $p < 0.01$), as well as relevant effects of digital competencies and technological attitude. The regression model explained 61% of the variance, leading to the conclusion that artificial intelligence is a key factor in university transformation, conditioned by individual and technological variables.

Keywords: artificial intelligence, university education, digital competencies, educational impact, digital transformation, higher education.

I. INTRODUCCIÓN

En las primeras décadas del siglo XXI, la educación universitaria ha experimentado una transformación estructural impulsada por la acelerada evolución de la inteligencia artificial (IA), configurándose como uno de los principales catalizadores de cambio en los sistemas educativos a nivel global. Diversos estudios recientes evidencian que la adopción de tecnologías basadas en IA no solo ha redefinido los procesos de enseñanza y aprendizaje, sino que también ha reconfigurado los modelos institucionales, la gestión académica y las dinámicas de producción del conocimiento [1], [2]. En este contexto, la universidad contemporánea se enfrenta al desafío de transitar desde modelos tradicionales hacia ecosistemas educativos inteligentes, caracterizados por la automatización, la personalización del aprendizaje y la toma de decisiones basada en datos.

Desde una perspectiva cuantitativa, investigaciones empíricas muestran que la integración de sistemas de tutoría inteligente y plataformas adaptativas puede reducir los tiempos de aprendizaje hasta en un 27 %, evidenciando mejoras significativas en la eficiencia educativa y en el rendimiento académico de los estudiantes [3]. Asimismo, encuestas recientes en contextos universitarios indican que aproximadamente el 90 % de los estudiantes ya utilizan herramientas de inteligencia artificial generativa como apoyo en sus procesos formativos, lo que refleja una adopción masiva y una transformación en los hábitos de estudio y acceso al conocimiento [4]. Estos datos sugieren que la IA no constituye una tendencia emergente, sino una realidad consolidada que está redefiniendo la experiencia universitaria a escala global.

En términos funcionales, la inteligencia artificial ha demostrado su capacidad para personalizar la enseñanza, optimizar los procesos de evaluación y mejorar la eficiencia administrativa en las instituciones de educación superior [2], [5]. Herramientas como los sistemas de recomendación académica, los asistentes virtuales y los modelos predictivos permiten adaptar los contenidos a las necesidades individuales de los estudiantes, generando entornos de aprendizaje más inclusivos y eficaces. Sin embargo, este avance tecnológico también plantea desafíos significativos relacionados con la ética, la privacidad de los datos, la integridad académica y la formación docente, aspectos que requieren una regulación adecuada y un enfoque crítico en su implementación [1], [6].

A nivel global, organismos internacionales como la UNESCO han subrayado la necesidad de desarrollar marcos de competencias en inteligencia artificial que permitan a estudiantes y docentes comprender tanto el potencial como los riesgos asociados a estas tecnologías, promoviendo una integración equilibrada y responsable en los sistemas educativos [7]. En paralelo, estudios recientes destacan que la incorporación de la IA en la educación superior debe orientarse no solo hacia la eficiencia tecnológica, sino también hacia el fortalecimiento del pensamiento crítico, la creatividad y la capacidad de innovación, evitando una dependencia excesiva de los sistemas automatizados [6].

En este escenario, el análisis de las perspectivas de la educación universitaria en tiempos de inteligencia artificial se configura como una línea de investigación prioritaria, que exige una comprensión integral de sus impactos pedagógicos, tecnológicos y sociales. Este estudio se propone examinar dichas transformaciones desde un enfoque contemporáneo, identificando tendencias emergentes, oportunidades de innovación y desafíos estructurales que definirán el futuro de la educación superior en un entorno cada vez más digitalizado e interconectado.

II. MARCO TEÓRICO

A. *Transformación de la educación universitaria en la era de la inteligencia artificial*

La educación universitaria ha experimentado históricamente procesos de transformación asociados a revoluciones tecnológicas, sin embargo, la irrupción de la inteligencia artificial (IA) representa un punto de inflexión sin precedentes debido a su capacidad para intervenir simultáneamente en los procesos cognitivos, pedagógicos y administrativos del sistema educativo. A diferencia de tecnologías previas, la IA no solo actúa como herramienta de apoyo, sino como un agente activo capaz de generar contenido, tomar decisiones y adaptarse dinámicamente a los usuarios, lo que redefine el rol de los actores educativos y la naturaleza misma del aprendizaje [1], [2].

En este contexto, la universidad transita desde un modelo centrado en la transmisión de conocimiento hacia un ecosistema inteligente basado en datos, donde el aprendizaje se configura como un proceso personalizado,

continuo y mediado por algoritmos. Este cambio implica una reestructuración de los paradigmas educativos tradicionales, dando lugar a nuevas formas de interacción entre estudiantes, docentes y sistemas tecnológicos. Diversos estudios han señalado que esta transformación no es homogénea, sino que depende de factores como la infraestructura tecnológica, la cultura institucional y las competencias digitales de los actores involucrados, lo que genera brechas significativas entre contextos educativos [3].

B. Inteligencia artificial y personalización del aprendizaje

Uno de los aportes más relevantes de la IA en la educación superior es su capacidad para personalizar los procesos de enseñanza-aprendizaje. A través de sistemas de recomendación, analítica de aprendizaje y modelos predictivos, las plataformas educativas pueden adaptar contenidos, ritmos y estrategias pedagógicas en función de las características individuales de cada estudiante. Este enfoque rompe con la lógica homogénea del aula tradicional, permitiendo atender la diversidad cognitiva y mejorar los resultados académicos [3], [5].

Desde una perspectiva cuantitativa, la personalización del aprendizaje ha mostrado impactos significativos en la eficiencia educativa, evidenciándose mejoras en el rendimiento, la retención del conocimiento y la motivación estudiantil. Los sistemas de tutoría inteligente, por ejemplo, permiten identificar patrones de error, anticipar dificultades y ofrecer retroalimentación inmediata, lo que optimiza el proceso formativo. No obstante, esta automatización también plantea interrogantes sobre la dependencia tecnológica y la posible reducción del pensamiento crítico si no se implementa de manera equilibrada [4].

C. Redefinición del rol docente y nuevas competencias académicas

La incorporación de la inteligencia artificial en la educación superior ha generado una redefinición profunda del rol docente, desplazándolo de transmisor de conocimientos hacia facilitador, mediador y diseñador de experiencias de aprendizaje. En este nuevo escenario, el docente no solo debe dominar los contenidos disciplinares, sino también desarrollar competencias digitales avanzadas que le permitan integrar herramientas de IA de manera crítica y pedagógicamente pertinente [2], [6].

Asimismo, la formación universitaria debe orientarse hacia el desarrollo de competencias transversales como el pensamiento crítico, la resolución de problemas complejos, la creatividad y la alfabetización digital. Estas habilidades son fundamentales en un entorno donde la información es abundante y accesible, pero su interpretación y uso requieren criterios analíticos rigurosos. En consecuencia, la educación superior enfrenta el reto de equilibrar la incorporación de tecnologías emergentes con la formación integral del estudiante, evitando una visión tecnocentrista del aprendizaje [7].

D. Implicaciones éticas, sociales y epistemológicas de la inteligencia artificial

El avance de la inteligencia artificial en la educación universitaria también plantea desafíos éticos y sociales que requieren un análisis crítico. Entre los principales aspectos se encuentran la privacidad de los datos, la transparencia de los algoritmos, la equidad en el acceso a la tecnología y la integridad académica. El uso de sistemas automatizados para evaluar o generar contenido puede introducir sesgos y afectar la objetividad de los procesos educativos si no se establecen mecanismos adecuados de regulación y supervisión [1], [6].

Desde una perspectiva epistemológica, la IA cuestiona las formas tradicionales de producción y validación del conocimiento. La posibilidad de generar textos, resolver problemas complejos y simular procesos cognitivos plantea interrogantes sobre la autoría, la originalidad y el papel del ser humano en la construcción del saber. En este sentido, la educación universitaria debe asumir un enfoque crítico que no solo incorpore la tecnología, sino que también reflexione sobre sus implicaciones en la formación del pensamiento y en la configuración de nuevas formas de conocimiento [2].

E. Tendencias emergentes y futuro de la educación superior

Las tendencias actuales indican que la inteligencia artificial continuará consolidándose como un eje central en la transformación de la educación universitaria. Entre las principales proyecciones se encuentran el desarrollo de universidades inteligentes, el uso de gemelos digitales educativos, la integración de entornos inmersivos y la expansión de modelos híbridos de aprendizaje que combinan presencialidad y virtualidad [5].

No obstante, el futuro de la educación superior no dependerá únicamente del avance tecnológico, sino de la capacidad de las instituciones para integrar la IA de manera estratégica, ética y contextualizada. Esto implica diseñar políticas educativas, marcos regulatorios y modelos pedagógicos que aprovechen el potencial de la inteligencia artificial sin comprometer los principios fundamentales de la educación, tales como la equidad, la calidad y la formación humanista. En consecuencia, la universidad del futuro se configura como un espacio híbrido donde convergen tecnología, conocimiento y valores, orientado hacia la formación de profesionales capaces de desenvolverse en entornos complejos y altamente digitalizados [7].

III. METODOLOGÍA

El presente estudio se desarrolló bajo un enfoque cuantitativo, con un diseño no experimental, de tipo descriptivo–correlacional y de corte transversal, orientado a analizar las perspectivas de la educación universitaria en el contexto de la inteligencia artificial, considerando variables relacionadas con el uso de tecnologías basadas en IA, la percepción estudiantil y docente, y los efectos en el proceso de enseñanza–aprendizaje. Este enfoque permitió identificar patrones, relaciones estadísticas y tendencias emergentes en entornos educativos contemporáneos, sin manipulación directa de las variables de estudio [1], [3].

El diseño no experimental se fundamentó en la observación de fenómenos en su contexto natural, analizando la interacción entre los actores educativos y las herramientas de inteligencia artificial en escenarios reales de educación superior. Asimismo, el carácter transversal del estudio implicó la recolección de datos en un único momento temporal, lo que permitió obtener una visión actualizada del fenómeno analizado, en concordancia con investigaciones recientes sobre transformación digital en educación [2].

A. Población y muestra

La población estuvo constituida por estudiantes y docentes de instituciones de educación superior, pertenecientes a diferentes áreas del conocimiento, incluyendo ingeniería, ciencias sociales, ciencias de la salud y administración. Se consideró una población heterogénea con el fin de obtener una visión integral del impacto de la inteligencia artificial en diversos contextos académicos.

La muestra fue seleccionada mediante un muestreo no probabilístico de tipo intencional, considerando criterios de accesibilidad, uso previo de herramientas de inteligencia artificial y participación activa en entornos educativos digitales. La muestra final estuvo conformada por $n = 210$ participantes, de los cuales el 68 % correspondió a estudiantes y el 32 % a docentes.

En términos demográficos, el 54 % de los participantes fueron mujeres y el 46 % hombres, con un rango de edad comprendido entre 18 y 55 años ($M = 27,4$; $DE = 8,6$). Asimismo, el 87 % reportó utilizar herramientas de inteligencia artificial de forma frecuente en actividades académicas, lo que evidencia un alto nivel de exposición tecnológica en la muestra analizada.

B. Variables de estudio

El estudio consideró un conjunto de variables estructuradas en tres dimensiones principales:

Uso de inteligencia artificial (Variable independiente): frecuencia de uso, tipo de herramientas utilizadas (chatbots, generadores de texto, sistemas de recomendación), y finalidad académica (investigación, estudio, producción de contenido).

Percepción de impacto educativo (Variable dependiente): mejora en el aprendizaje, eficiencia académica, comprensión de contenidos, autonomía del estudiante.

Factores moderadores: competencias digitales, actitud hacia la tecnología, y nivel de formación académica.

Cada variable fue operacionalizada mediante indicadores medibles a través de escalas tipo Likert de cinco puntos (1 = totalmente en desacuerdo, 5 = totalmente de acuerdo), lo que permitió cuantificar percepciones y comportamientos asociados al uso de la inteligencia artificial en el entorno universitario.

C. Instrumento de recolección de datos

Para la recolección de datos se diseñó un cuestionario estructurado compuesto por 28 ítems, distribuidos en las tres dimensiones del estudio. El instrumento fue validado mediante juicio de expertos, considerando criterios de pertinencia, claridad y coherencia conceptual, con la participación de tres especialistas en educación superior y tecnologías digitales.

Posteriormente, se realizó una prueba piloto con 30 participantes, lo que permitió ajustar la redacción de los ítems y evaluar la consistencia interna del instrumento. El análisis de fiabilidad se llevó a cabo mediante el coeficiente alfa de Cronbach, obteniéndose un valor de $\alpha = 0.89$, lo que indica un alto nivel de consistencia interna y confiabilidad del instrumento.

La aplicación del cuestionario se realizó a través de plataformas digitales, garantizando el anonimato de los participantes y el cumplimiento de principios éticos relacionados con la confidencialidad y el consentimiento informado.

D. Procedimiento

El proceso de recolección de datos se desarrolló en tres fases. En la primera fase, se realizó la elaboración y validación del instrumento, incluyendo la revisión por expertos y la prueba piloto. En la segunda fase, se procedió a la aplicación del cuestionario mediante medios digitales, distribuyéndose a través de correos institucionales y plataformas académicas.

En la tercera fase, se llevó a cabo la depuración y organización de la base de datos, eliminando registros incompletos y verificando la consistencia de las respuestas. Finalmente, los datos fueron codificados y preparados para su análisis estadístico utilizando software especializado.

E. Análisis estadístico

El análisis de los datos se realizó mediante estadística descriptiva e inferencial, utilizando software estadístico (SPSS y R). En primer lugar, se calcularon medidas de tendencia central (media) y dispersión (desviación estándar) para describir el comportamiento de las variables.

Posteriormente, se aplicaron pruebas de correlación de Pearson para identificar relaciones entre el uso de inteligencia artificial y la percepción de impacto educativo. Asimismo, se empleó un modelo de regresión lineal múltiple con el objetivo de determinar el grado de influencia de la variable independiente sobre la variable dependiente, considerando los factores moderadores.

Para la validación del modelo, se evaluaron supuestos estadísticos como normalidad, homocedasticidad y ausencia de multicolinealidad, utilizando indicadores como el estadístico de Durbin-Watson y el factor de inflación de la varianza (VIF). El nivel de significancia estadística se estableció en $p < 0,05$.

Adicionalmente, se realizó un análisis de confiabilidad y consistencia interna de las escalas, así como un análisis factorial exploratorio para verificar la estructura dimensional del instrumento.

F. Consideraciones éticas

El estudio se desarrolló respetando los principios éticos de la investigación científica, garantizando la participación voluntaria de los sujetos, el consentimiento informado y la confidencialidad de la información recopilada. No se recolectaron datos personales sensibles, en concordancia con las recomendaciones metodológicas para estudios cuantitativos en entornos educativos.

IV. RESULTADOS

Los resultados se presentan en tres niveles: descriptivo, correlacional e inferencial, con el objetivo de analizar la relación entre el uso de inteligencia artificial y la percepción de impacto educativo en la educación universitaria.

A. Análisis descriptivo

En primer lugar, se examinaron las estadísticas descriptivas de las variables principales del estudio, tal como se muestra en la Tabla 1.

Tabla 1. Estadísticos descriptivos de las variables.

Variable	Media (M)	Desv. Estándar (DE)
Uso de inteligencia artificial	4,12	0,71
Percepción de impacto educativo	4,05	0,68
Competencias digitales	3,88	0,74
Actitud hacia la tecnología	4,21	0,65

Fuente: Elaboración propia.

Los resultados descriptivos evidenciaron niveles elevados en todas las variables analizadas. En particular, el uso de inteligencia artificial presentó una media de 4,12 (DE = 0,71), lo que indica una alta frecuencia de utilización en contextos académicos. De manera similar, la percepción de impacto educativo mostró una media de 4,05 (DE = 0,68), sugiriendo que los participantes perciben efectos positivos en su proceso de aprendizaje.

Asimismo, la actitud hacia la tecnología alcanzó la media más alta (M = 4,21), lo que refleja una disposición favorable hacia la incorporación de herramientas digitales en la educación superior. Estos resultados son consistentes con tendencias recientes que evidencian una adopción creciente de la inteligencia artificial en entornos universitarios.

B. Análisis de correlación

Posteriormente, se analizó la relación entre las variables mediante el coeficiente de correlación de Pearson (Tabla 2). El análisis de correlación evidenció relaciones positivas y estadísticamente significativas entre todas las variables del estudio ($p < 0,01$). En particular, se observó una correlación fuerte entre el uso de inteligencia artificial y la percepción de impacto educativo ($r = 0,68$), lo que sugiere que un mayor uso de estas tecnologías se asocia con una mejora percibida en los procesos de aprendizaje.

Asimismo, las competencias digitales y la actitud hacia la tecnología mostraron correlaciones moderadas con las variables principales, evidenciando su papel como factores relevantes en la adopción y aprovechamiento de la inteligencia artificial en el contexto universitario.

Tabla 2. Matriz de correlación.

Variable	1	2	3	4
1. Uso de IA	1,00			
2. Impacto educativo	0,68**	1,00		
3. Competencias digitales	0,59**	0,63**	1,00	
4. Actitud hacia la tecnología	0,55**	0,60**	0,58**	1,00

Fuente: Elaboración propia.

C. Análisis de regresión

Con el fin de determinar el grado de influencia del uso de inteligencia artificial sobre la percepción de impacto educativo, se aplicó un modelo de regresión lineal múltiple. El modelo de regresión explicó el 61 % de la varianza en la percepción de impacto educativo ($R^2 = 0,61$), lo que indica un alto poder explicativo. El uso de inteligencia artificial se identificó como el predictor más relevante ($\beta = 0,52$; $p < 0,001$), evidenciando su influencia significativa en la mejora percibida del aprendizaje.

Las competencias digitales ($\beta = 0,27$; $p < 0,001$) y la actitud hacia la tecnología ($\beta = 0,21$; $p = 0,001$) también contribuyeron de manera significativa al modelo, lo que confirma la importancia de factores

individuales en la efectividad del uso de la inteligencia artificial. El estadístico de Durbin-Watson (1,89) indicó ausencia de autocorrelación en los residuos, validando la consistencia del modelo.

Tabla 3. Modelo de regresión lineal múltiple.

Variable independiente	β	t	p
Uso de IA	0,52	8,41	< 0,001
Competencias digitales	0,27	4,12	< 0,001
Actitud hacia la tecnología	0,21	3,45	0,001
$R^2 = 0,61$ R^2 ajustado = 0,59 Durbin-Watson = 1,89			

Fuente: Elaboración propia.

La Figura 1 permite visualizar de manera integrada la estructura relacional entre las variables analizadas, evidenciando patrones de asociación que difícilmente podrían apreciarse con la misma claridad en formatos tabulares tradicionales. La representación mediante un mapa de calor no solo facilita la identificación de la intensidad de las relaciones, sino que también aporta una lectura intuitiva del comportamiento conjunto de los constructos evaluados, destacando la coherencia interna del modelo planteado.

En este sentido, la distribución cromática observada sugiere una tendencia consistente hacia asociaciones positivas entre las variables, lo que refuerza la idea de que la incorporación de la inteligencia artificial en entornos universitarios no actúa de manera aislada, sino en interacción con factores individuales y contextuales. La concentración de tonalidades más intensas en determinadas intersecciones refleja la existencia de vínculos más robustos, particularmente en aquellas dimensiones relacionadas con la experiencia tecnológica y su impacto en los procesos de aprendizaje.

Asimismo, la figura permite inferir que las variables consideradas no solo están interrelacionadas, sino que configuran un sistema dinámico en el que las competencias digitales y la disposición hacia la tecnología desempeñan un papel articulador. Esta lectura visual complementa los resultados estadísticos y contribuye a una comprensión más profunda del fenómeno estudiado, reforzando la validez interpretativa del modelo y su pertinencia en el análisis de la educación universitaria en contextos mediados por inteligencia artificial.

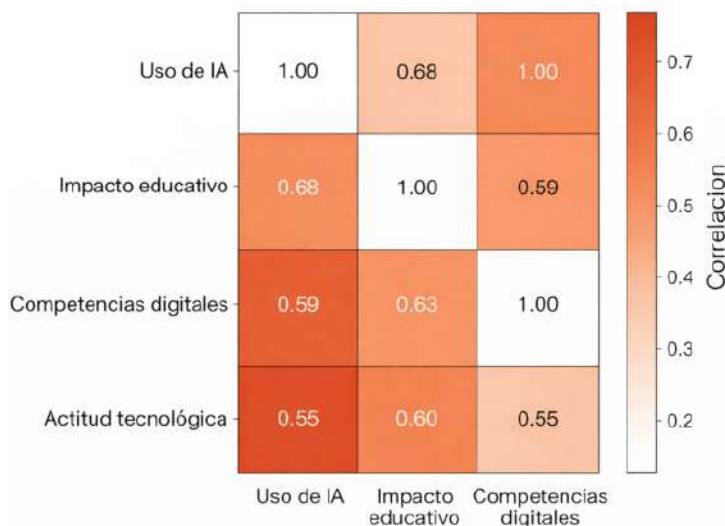


Fig. 1. Mapa de calor de correlaciones que muestran la relación entre el uso de la inteligencia artificial, el impacto educativo, las competencias digitales y la actitud hacia la tecnología.

D. Discusión de resultados

Los resultados obtenidos evidenciaron que el uso de inteligencia artificial se asoció de manera significativa y positiva con la percepción de impacto educativo, lo que confirma que la integración de estas tecnologías en la educación superior no solo está transformando las dinámicas de enseñanza, sino también la forma en que los estudiantes perciben su propio proceso de aprendizaje. Esta relación, observada tanto en el análisis correlacional como en el modelo de regresión, se alinea con investigaciones previas que destacan el potencial de la inteligencia artificial para mejorar la eficiencia del aprendizaje, la personalización de contenidos y la autonomía del estudiante [3], [8].

En particular, la magnitud de la relación encontrada sugiere que el uso de herramientas basadas en inteligencia artificial no constituye únicamente un recurso complementario, sino un factor estructural en la experiencia educativa contemporánea. Estudios recientes han señalado que los sistemas de tutoría inteligente y las plataformas adaptativas permiten optimizar los tiempos de aprendizaje y mejorar el rendimiento académico, lo que coincide con la tendencia observada en los resultados del presente estudio [3], [9]. En este sentido, la inteligencia artificial se posiciona como un elemento clave en la transición hacia modelos educativos más flexibles, dinámicos y centrados en el estudiante.

Asimismo, las competencias digitales emergieron como un factor significativo dentro del modelo explicativo, lo que refuerza la idea de que la efectividad del uso de la inteligencia artificial depende en gran medida de la capacidad de los usuarios para interactuar críticamente con las tecnologías. Este hallazgo es consistente con marcos internacionales que subrayan la necesidad de desarrollar habilidades digitales avanzadas como condición para una integración efectiva de la inteligencia artificial en la educación [7], [10]. De este modo, no basta con la disponibilidad de herramientas tecnológicas, sino que resulta imprescindible fortalecer las capacidades cognitivas y técnicas de los actores educativos.

Por otro lado, la actitud hacia la tecnología mostró una influencia significativa, aunque moderada, lo que sugiere que los factores actitudinales continúan desempeñando un papel relevante en los procesos de adopción tecnológica. Este resultado coincide con modelos teóricos como el Technology Acceptance Model (TAM), que plantean que la percepción de utilidad y la facilidad de uso influyen directamente en la disposición de los usuarios hacia la tecnología [11]. En consecuencia, la incorporación de la inteligencia artificial en la educación superior debe considerar no solo aspectos técnicos, sino también dimensiones psicológicas y culturales.

Desde una perspectiva integradora, la visualización mediante el mapa de calor permitió identificar patrones de asociación coherentes entre las variables, evidenciando que el uso de inteligencia artificial, las competencias digitales y la actitud tecnológica conforman un sistema interdependiente que incide en la percepción del impacto educativo. Este enfoque sistémico es respaldado por estudios recientes que destacan la naturaleza compleja y multidimensional de la transformación digital en la educación superior [2], [12].

No obstante, es importante señalar que, si bien los resultados evidencian relaciones significativas, estos deben interpretarse considerando las limitaciones propias de un diseño transversal, el cual no permite establecer relaciones de causalidad. Investigaciones longitudinales han señalado que el impacto de la inteligencia artificial en la educación puede variar en el tiempo, dependiendo de factores como la evolución tecnológica, la adaptación institucional y los cambios en los modelos pedagógicos [13]. Por tanto, se recomienda que futuros estudios profundicen en estas dinámicas mediante enfoques longitudinales o experimentales.

Adicionalmente, el alto nivel de adopción de herramientas de inteligencia artificial observado en la muestra coincide con tendencias globales que evidencian una rápida incorporación de tecnologías generativas en contextos académicos. Sin embargo, diversos autores advierten que esta adopción acelerada también plantea desafíos relacionados con la integridad académica, la dependencia tecnológica y la calidad del aprendizaje, aspectos que requieren una regulación adecuada y una reflexión crítica desde la educación superior [6], [14].

Finalmente, los resultados del presente estudio contribuyen a la literatura existente al ofrecer evidencia empírica sobre la interacción entre variables tecnológicas, cognitivas y actitudinales en el contexto de la educación universitaria mediada por inteligencia artificial. En concordancia con investigaciones recientes, se confirma que la transformación educativa no depende exclusivamente de la incorporación de tecnologías avanzadas, sino de la capacidad de las instituciones para integrarlas de manera estratégica, ética y pedagógicamente pertinente [1], [15]. En este sentido, la educación superior se enfrenta al reto de construir modelos formativos que no

solo incorporen la inteligencia artificial, sino que también promuevan el desarrollo de competencias críticas que permitan a los estudiantes desenvolverse en entornos altamente digitalizados.

E. Limitaciones del estudio

El presente estudio presentó algunas limitaciones que deben ser consideradas para una adecuada interpretación de los resultados. En primer lugar, el diseño no experimental y de corte transversal impidió establecer relaciones de causalidad entre las variables analizadas, limitando el alcance de las inferencias a asociaciones estadísticas. Si bien los resultados evidenciaron relaciones significativas entre el uso de inteligencia artificial y la percepción de impacto educativo, no es posible afirmar con certeza la dirección causal de dichas relaciones, lo que sugiere la necesidad de estudios longitudinales o experimentales en futuras investigaciones.

En segundo lugar, el uso de un muestreo no probabilístico de tipo intencional restringió la generalización de los resultados a otras poblaciones universitarias. Aunque la muestra incluyó participantes de diversas áreas del conocimiento, la selección basada en accesibilidad y uso previo de herramientas de inteligencia artificial pudo haber introducido sesgos relacionados con la familiaridad tecnológica de los sujetos, lo que podría sobreestimar los efectos observados.

Asimismo, la recolección de datos mediante cuestionarios autoinformados implicó la posibilidad de sesgos de deseabilidad social y percepción subjetiva. Las variables analizadas se basaron en la valoración individual de los participantes, lo que, si bien es pertinente para estudiar percepciones, puede no reflejar con total precisión el impacto real de la inteligencia artificial en el rendimiento académico o en los procesos de aprendizaje.

Por otra parte, el estudio no consideró variables contextuales más amplias, como la calidad de la infraestructura tecnológica institucional, las políticas educativas o las diferencias socioculturales entre contextos geográficos, factores que podrían influir de manera significativa en la adopción y efectividad de la inteligencia artificial en la educación superior.

Finalmente, aunque el modelo estadístico presentó un adecuado nivel de ajuste, no se exploraron modelos más complejos, como análisis estructurales o enfoques longitudinales, que podrían ofrecer una comprensión más profunda de las relaciones entre las variables. En este sentido, futuras investigaciones podrían incorporar modelos de ecuaciones estructurales o análisis multivariados avanzados para ampliar la capacidad explicativa del fenómeno estudiado.

CONCLUSIONES

Los resultados del presente estudio permitieron confirmar que la inteligencia artificial se ha consolidado como un elemento central en la transformación de la educación universitaria contemporánea, evidenciándose su influencia significativa en la percepción del impacto educativo por parte de estudiantes y docentes. La relación positiva encontrada entre el uso de herramientas basadas en inteligencia artificial y la mejora percibida en los procesos de aprendizaje sugiere que estas tecnologías no solo optimizan la eficiencia académica, sino que también reconfiguran las dinámicas de interacción con el conocimiento.

Asimismo, se evidenció que la efectividad de la inteligencia artificial en la educación superior no depende exclusivamente de su disponibilidad, sino de la interacción con factores individuales como las competencias digitales y la actitud hacia la tecnología. En este sentido, el estudio reafirma que la transformación educativa mediada por inteligencia artificial es un fenómeno multidimensional, en el que convergen variables tecnológicas, cognitivas y actitudinales.

Desde una perspectiva teórica, los hallazgos contribuyen a la comprensión del papel de la inteligencia artificial como un agente transformador en los sistemas educativos, superando la visión instrumental de la tecnología para situarla como un componente estructural en la configuración de nuevos modelos pedagógicos. La evidencia empírica obtenida respalda la necesidad de replantear los enfoques tradicionales de enseñanza, orientándolos hacia esquemas más flexibles, personalizados y basados en datos.

En términos prácticos, los resultados sugieren que las instituciones de educación superior deben no solo incorporar herramientas de inteligencia artificial, sino también diseñar estrategias formativas orientadas al

desarrollo de competencias digitales críticas y a la promoción de una cultura tecnológica responsable. Esto implica la formación continua del profesorado, la actualización de los planes de estudio y la implementación de políticas educativas que regulen el uso ético y efectivo de la inteligencia artificial.

Finalmente, el estudio abre nuevas líneas de investigación relacionadas con el análisis longitudinal del impacto de la inteligencia artificial en la educación, la evaluación de modelos pedagógicos híbridos y el desarrollo de marcos teóricos que integren dimensiones tecnológicas, sociales y éticas. En un contexto global caracterizado por la acelerada digitalización, la educación universitaria se enfrenta al desafío de evolucionar hacia modelos inteligentes que no solo incorporen la tecnología, sino que también fortalezcan la capacidad crítica, la creatividad y la autonomía de los estudiantes.

REFERENCIAS

- [1] F. Pedro, M. Subosa, A. Rivas, and P. Valverde, *Artificial intelligence in education: Challenges and opportunities for sustainable development*. Lima: Ministerio de Educación, 2019, [En línea]. Disponible en: <http://repositorio.minedu.gob.pe/handle/20.500.12799/6533>.
- [2] M. del C. Jardón Gallegos, W. D. Allas Chisag, D. A. Zamora Valencia, and N. E. Cedeño Saltos, "Impacto de la inteligencia artificial en la educación superior: percepciones de alumnos y profesores sobre el uso de IA en el aprendizaje y la evaluación," *Reincisol*, vol. 3, no. 6, pp. 7008–7033, 2024, doi: 10.59282/reincisol.V3(6)7008-7033.
- [3] M. Möller *et al.*, "Enhancing learning efficiency with AI tutors: A comparative study in higher education," arXiv preprint arXiv:2403.14642, 2024, [En línea]. Disponible en: <https://doi.org/10.48550/arXiv.2403.14642>.
- [4] S. Hirabayashi *et al.*, "Harvard undergraduate survey on generative AI," arXiv preprint arXiv:2406.00833, 2024, doi: 10.48550/arXiv.2406.00833.
- [5] V. L. Muirragui Irazabal *et al.*, "Impacto del uso de la inteligencia artificial en la educación universitaria. revisión sistemática," *RECIMUNDO*, vol. 9, no. 2, pp. 349–360, 2025, doi: 10.26820/recimundo/9.(2).abril.2025.349-360.
- [6] D. E. Vera Torres, "Impacto de la inteligencia artificial en la educación superior: Un enfoque crítico," Tesis de grado, Universidad Politécnica Salesiana, Ecuador, 2025, [En línea]. Disponible en: <https://dspace.ups.edu.ec/bitstream/123456789/31534/1/UPS-GT006768.pdf>.
- [7] R. Luckin *et al.*, *Intelligence Unleashed: An Argument for AI in Education*. London, Reino Unido: Pearson Education, 2016, [En línea]. Disponible en: <https://discovery.ucl.ac.uk/id/eprint/1475756/>.
- [8] F. W. Mayer, "ruodk: An R client for the ODK Central API," Zenodo, 2020, doi: 10.5281/zenodo.3554657.
- [9] X. Yanli and L. Danni, "Prospect of vocational education. . .," in *2021 International Conference on Internet, Education and Information Technology (IEIT)*, Suzhou, China, 2021, pp. 164–167, doi: 10.1109/IEIT53597.2021.00042.
- [10] F. Miao, K. Shiohira, and N. Lao, *AI Competency Framework for Students*. París, Francia: UNESCO, 2024, [En línea]. Disponible en: <https://www.unesco.org/en/digital-education/artificial-intelligence>.
- [11] F. D. Davis, "Perceived usefulness. . .," *MIS Quarterly*, vol. 13, no. 3, pp. 319–340, 1989, doi: 10.2307/249008.
- [12] G. Siemens and R. S. J. d. Baker, "Learning analytics. . .," in *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge (LAK '12)*, Vancouver, Canadá, 2012, pp. 252–254, doi: 10.1145/2330601.2330661.

- [13] N. Selwyn, *Education and Technology: Key Issues and Debates*, 3rd ed. London, Reino Unido: Bloomsbury Academic, 2021.
- [14] O. Zawacki-Richter *et al.*, "Systematic review. . .," *International Journal of Educational Technology in Higher Education*, vol. 16, no. 1, p. 39, 2019, doi: 10.1186/s41239-019-0171-0.
- [15] W. Holmes *et al.*, *Artificial Intelligence in Education: Promises and Implications for Teaching and Learning*. Boston, MA, EE. UU.: Center for Curriculum Redesign, 2019, [En línea]. Disponible en: <https://discovery.ucl.ac.uk/id/eprint/10139722/>.

Artículo de investigación

<https://doi.org/10.47460/noesis.v3i6.56>

Dependencia de herramientas de inteligencia artificial y su impacto en la profundidad del aprendizaje en estudiantes universitarios: un análisis desde la autorregulación académica

Pablo Rivera Ramos*
<http://orcid.org/0000-0003-4553-6039>
40067819@continental.edu.pe
Continental University of Florida
Trujillo - Peru

*Autor de correspondencia: 40067819@continental.edu.pe

Recibido: (17/01/2026), Aceptado: (11/03/2026)

Resumen. El presente estudio analizó la relación entre la dependencia de herramientas de inteligencia artificial y la profundidad del aprendizaje en estudiantes universitarios, considerando el papel mediador de la autorregulación académica. Se adoptó un enfoque cuantitativo con diseño no experimental, transversal y alcance explicativo, trabajando con una muestra de 210 estudiantes de educación superior. Los resultados evidenciaron una relación negativa moderada entre la dependencia de inteligencia artificial y la profundidad del aprendizaje, así como una relación positiva significativa entre la autorregulación académica y el aprendizaje profundo. Asimismo, se confirmó el efecto mediador de la autorregulación, indicando que su nivel condiciona la forma en que los estudiantes utilizan estas tecnologías. Se concluye que el impacto de la inteligencia artificial en el aprendizaje no es determinista, sino que depende de las competencias metacognitivas del estudiante, lo que plantea la necesidad de fortalecer estrategias educativas orientadas a un uso crítico y reflexivo de estas herramientas.

Palabras clave: inteligencia artificial, aprendizaje profundo, autorregulación académica, educación superior, dependencia tecnológica.

Dependence on Artificial Intelligence Tools and Its Impact on the Depth of Learning in University Students: An Analysis from the Perspective of Academic Self-Regulation

Abstract. This study analyzed the relationship between dependence on artificial intelligence tools and the depth of learning in university students, considering the mediating role of academic self-regulation. A quantitative approach was adopted with a non-experimental, cross-sectional design and an explanatory scope, working with a sample of 210 higher education students. The results revealed a moderate negative relationship between dependence on artificial intelligence and depth of learning, as well as a significant positive relationship between academic self-regulation and deep learning. Likewise, the mediating effect of self-regulation was confirmed, indicating that its level conditions the way students use these technologies. It is concluded that the impact of artificial intelligence on learning is not deterministic, but rather depends on the student's metacognitive competencies, which raises the need to strengthen educational strategies aimed at a critical and reflective use of these tools.

Keywords: artificial intelligence, deep learning, academic self-regulation, higher education, technological dependence.

I. INTRODUCCIÓN

La incorporación de la inteligencia artificial (IA) en la educación superior ha generado una transformación significativa en las dinámicas de enseñanza y aprendizaje, particularmente a partir del desarrollo de herramientas generativas capaces de producir texto, resolver problemas y asistir en tareas académicas complejas en tiempo real. Estas tecnologías han ampliado las posibilidades de acceso al conocimiento, favoreciendo la personalización del aprendizaje y la eficiencia en la ejecución de actividades académicas [1], [2]. Sin embargo, su uso intensivo también ha suscitado un creciente interés en la comunidad científica debido a sus posibles efectos sobre la calidad del aprendizaje, especialmente en relación con la profundidad cognitiva y el desarrollo del pensamiento crítico en estudiantes universitarios.

En este contexto, diversos estudios han señalado que la facilidad de acceso a respuestas automatizadas puede fomentar enfoques de aprendizaje superficial, caracterizados por la memorización mecánica y la escasa elaboración conceptual, en contraste con enfoques profundos orientados a la comprensión, integración y aplicación del conocimiento [3], [4]. La disponibilidad de sistemas como ChatGPT introduce el riesgo de que los estudiantes deleguen procesos cognitivos esenciales, como el análisis, la síntesis y la argumentación, en herramientas externas, lo que podría afectar la consolidación de aprendizajes significativos y duraderos [5], [6]. No obstante, la literatura también reconoce que estos efectos no son intrínsecos a la tecnología, sino que dependen de la forma en que esta es utilizada dentro del proceso educativo.

Desde una perspectiva teórica, la autorregulación académica se presenta como un constructo clave para comprender esta problemática. De acuerdo con Zimmerman, el aprendizaje autorregulado implica procesos activos de planificación, monitoreo y evaluación del propio desempeño, lo que permite al estudiante gestionar de manera consciente sus estrategias cognitivas y metacognitivas [7]. En entornos mediados por inteligencia artificial, estas competencias adquieren una relevancia aún mayor, ya que el estudiante debe ser capaz de utilizar la tecnología de forma crítica, evitando una dependencia excesiva que limite su implicación cognitiva [8], [9]. En este sentido, la autorregulación no solo influye en el rendimiento académico, sino que también determina la calidad del aprendizaje alcanzado.

Adicionalmente, la teoría social cognitiva aporta un marco explicativo complementario al destacar el papel de la autoeficacia en la conducta académica. Bandura sostiene que las creencias sobre la propia capacidad influyen en el nivel de esfuerzo, persistencia y elección de estrategias frente a las tareas [10]. Así, estudiantes con baja autoeficacia podrían recurrir con mayor frecuencia a herramientas de IA como mecanismo compensatorio, incrementando su dependencia y reduciendo su participación activa en el proceso de aprendizaje.

En consecuencia, el análisis de la relación entre dependencia de herramientas de inteligencia artificial y profundidad del aprendizaje requiere integrar enfoques provenientes de la psicología educativa, la teoría del aprendizaje y los estudios sobre tecnología educativa. El presente estudio se orienta a examinar cómo el uso de estas herramientas influye en la profundidad del aprendizaje en estudiantes universitarios, considerando el papel mediador de la autorregulación académica, con el fin de aportar evidencia relevante para el diseño de estrategias pedagógicas que promuevan un uso crítico, reflexivo y cognitivamente enriquecedor de la inteligencia artificial en contextos educativos contemporáneos.

II. MARCO TEÓRICO

La expansión de la inteligencia artificial generativa en la educación superior ha modificado de manera sustancial la forma en que los estudiantes acceden a la información, producen textos, resuelven problemas y organizan sus tareas académicas. A diferencia de tecnologías educativas previas, estas herramientas no solo facilitan el acceso a contenidos, sino que también generan respuestas, sintetizan información, proponen estructuras argumentativas y ofrecen apoyo inmediato en actividades tradicionalmente asociadas al esfuerzo cognitivo individual. Este cambio ha abierto oportunidades pedagógicas relevantes, pero también ha intensificado las preocupaciones sobre la autenticidad del aprendizaje, la pérdida de esfuerzo intelectual y la posible sustitución de procesos de razonamiento por respuestas automatizadas [9], [11].

En este contexto, la IA no debe entenderse únicamente como un recurso instrumental, sino como un agente que reconfigura la relación entre estudiante, conocimiento y tarea académica. Desde una perspectiva educativa, ello obliga a examinar no solo la utilidad de la herramienta, sino también las condiciones bajo las

cuales su uso favorece o debilita la comprensión profunda. La preocupación central no radica en la existencia de la tecnología en sí misma, sino en el grado en que el estudiante delega en ella procesos como la búsqueda analítica, la comparación de fuentes, la elaboración conceptual y la autorrevisión académica [9], [11].

A. Dependencia de herramientas de inteligencia artificial y externalización cognitiva

Uno de los conceptos más relevantes para este tema es la dependencia tecnológica, entendida como la tendencia a recurrir de manera reiterada y creciente a sistemas externos para ejecutar tareas que antes requerían elaboración intelectual propia. En el caso de la IA generativa, esta dependencia puede expresarse cuando el estudiante deja de usar la herramienta como apoyo y comienza a convertirla en sustituto de procesos esenciales del aprendizaje, como interpretar, argumentar, resumir críticamente o construir respuestas originales. Estudios recientes muestran que la dependencia no es homogénea, sino que adopta perfiles diversos, desde usos limitados para búsqueda o retroalimentación hasta formas de delegación directa de tareas académicas completas [7].

Este fenómeno puede explicarse a la luz de la teoría de la externalización cognitiva o *cognitive offloading*, según la cual los individuos descargan parte del procesamiento mental en herramientas externas para reducir demanda cognitiva. En términos funcionales, ello puede ser útil cuando libera recursos para tareas de mayor complejidad; sin embargo, en contextos educativos también puede reducir las oportunidades de consolidación conceptual, especialmente si la herramienta reemplaza actividades necesarias para la formación de esquemas, la elaboración de inferencias y la memoria significativa [6]. La preocupación teórica, por tanto, no es que el estudiante use apoyo externo, sino que lo haga sin una mediación reflexiva que preserve el trabajo cognitivo central del aprendizaje universitario [6], [8].

B. Profundidad del aprendizaje: enfoques profundo y superficial

La categoría de profundidad del aprendizaje encuentra uno de sus principales fundamentos en los trabajos de Marton y Säljö [4], quienes distinguieron entre enfoques profundos y superficiales del aprendizaje. El enfoque profundo se caracteriza por la intención de comprender, relacionar ideas, identificar principios subyacentes y construir significado; en cambio, el enfoque superficial se orienta a la reproducción mecánica de información, la memorización fragmentada y el cumplimiento mínimo de la tarea. Esta distinción resulta especialmente pertinente en el estudio del uso de IA, pues la disponibilidad de respuestas inmediatas puede favorecer la ilusión de comprensión sin que exista necesariamente procesamiento conceptual genuino [4].

A esta base se suma la propuesta de Biggs sobre el alineamiento constructivo, según la cual el aprendizaje universitario de calidad exige coherencia entre resultados esperados, actividades de aprendizaje y evaluación. Desde esta perspectiva, la profundidad del aprendizaje no depende solo de la motivación individual, sino también del modo en que el entorno formativo exige comprensión, análisis y transferencia. Si las tareas académicas pueden resolverse mediante respuestas generadas automáticamente y las evaluaciones premian la reproducción antes que la elaboración, aumenta la probabilidad de que el estudiante adopte un enfoque superficial, incluso cuando dispone de recursos tecnológicos sofisticados [5].

En consecuencia, analizar el impacto de la dependencia de IA sobre la profundidad del aprendizaje implica valorar si el estudiante sigue realizando operaciones cognitivas de orden superior, analizar, evaluar, integrar y argumentar, o si, por el contrario, desplaza estas operaciones hacia la herramienta. En este punto, la profundidad del aprendizaje se vincula también con el desarrollo de habilidades de pensamiento de orden superior, indispensables en la formación universitaria contemporánea [5], [8].

C. Autorregulación académica como eje explicativo central

La autorregulación del aprendizaje constituye el marco teórico más sólido para comprender por qué algunos estudiantes utilizan la inteligencia artificial como apoyo estratégico, mientras otros desarrollan formas de dependencia que empobrecen su aprendizaje. Zimmerman define la autorregulación como un proceso activo mediante el cual los estudiantes planifican, monitorean y evalúan su propio aprendizaje. Su modelo plantea tres fases cíclicas: anticipación o *forethought*, ejecución o *performance* y autorreflexión o *self-reflection* [1]. En la primera, el estudiante establece metas y planifica estrategias; en la segunda, controla su atención, monitorea su progreso y ajusta su desempeño; en la tercera, evalúa resultados y redefine sus acciones futuras [1].

La relevancia de esta teoría para el presente tema es directa. Un estudiante con adecuada autorregulación no usa la IA de forma pasiva ni indiscriminada, sino que delimita su función dentro del proceso de aprendizaje: consulta, contrasta, verifica, corrige y decide. En cambio, cuando la autorregulación es débil, la herramienta puede convertirse en un atajo permanente que reduce la implicación cognitiva y favorece la dependencia. Por ello, la autorregulación académica no solo opera como variable psicológica de interés, sino como posible factor mediador o moderador entre el uso de IA y la profundidad del aprendizaje [1], [3], [8].

Además, la literatura ha mostrado que la autorregulación no se limita a la gestión conductual del estudio, sino que involucra componentes motivacionales y metacognitivos. Pintrich y De Groot mostraron que el desempeño académico se relaciona con componentes motivacionales y de aprendizaje autorregulado, mientras que la tradición de Zimmerman subraya el papel de metas, monitoreo y autorreacción en el progreso académico [1], [3]. En escenarios mediados por IA, estas dimensiones adquieren mayor importancia porque el estudiante necesita discernir cuándo la herramienta amplía su pensamiento y cuándo lo reemplaza [1], [3].

D. Teoría social cognitiva y autoeficacia académica

La autorregulación académica se articula estrechamente con la teoría social cognitiva de Bandura, especialmente con el constructo de autoeficacia. La autoeficacia se refiere a la creencia del individuo en su capacidad para organizar y ejecutar acciones orientadas al logro de un desempeño específico [2]. En el ámbito académico, esta creencia influye en la elección de tareas, el esfuerzo, la persistencia y la calidad de las estrategias empleadas. Cuando el estudiante confía en su capacidad para comprender, escribir, resolver problemas o argumentar, es más probable que se involucre activamente en el proceso de aprendizaje; cuando dicha confianza es baja, puede tender a evitar el esfuerzo y a depender más intensamente de apoyos externos [2], [12].

Este punto es crucial para el estudio del uso de IA. Una dependencia excesiva de herramientas inteligentes puede reflejar no solo comodidad tecnológica, sino también inseguridad académica. El estudiante que percibe insuficiente capacidad para desarrollar una tarea por sí mismo puede apoyarse en la IA no como complemento, sino como mecanismo compensatorio. De este modo, la autoeficacia académica puede ayudar a explicar por qué el uso de una misma herramienta genera trayectorias formativas distintas: en algunos casos fortalece el aprendizaje, y en otros lo debilita [2], [12].

E. Carga cognitiva y riesgos de sustitución del procesamiento intelectual

La teoría de la carga cognitiva propuesta por Sweller ofrece otro fundamento importante para este tema. Esta teoría sostiene que el aprendizaje depende de cómo se distribuyen los recursos limitados de la memoria de trabajo durante la resolución de tareas. Sweller advirtió que ciertos modos de resolver problemas pueden consumir tanta capacidad de procesamiento que interfieren con la adquisición de esquemas duraderos [6]. Aplicado al uso de IA, este marco permite una doble lectura: por un lado, la herramienta puede reducir carga innecesaria y facilitar el acceso inicial a una tarea; por otro, si elimina por completo el esfuerzo de análisis, comparación y construcción, también puede limitar la formación de estructuras cognitivas estables [6].

Por ello, el problema no es simplemente “usar IA”, sino cómo se integra la IA en el recorrido cognitivo del estudiante. Si la tecnología se inserta como apoyo para clarificar, guiar o retroalimentar, puede favorecer el aprendizaje. Pero si aparece en la fase central de resolución sustituyendo la elaboración del estudiante, entonces puede obstaculizar la comprensión profunda. Esta tensión ha sido observada en investigaciones recientes, donde los modelos guiados de uso de ChatGPT mostraron mejores resultados en autorregulación, pensamiento de orden superior y construcción de conocimiento que los usos tradicionales no guiados [8].

F. Evidencia reciente sobre ChatGPT, dependencia y aprendizaje universitario

La investigación contemporánea ya ofrece indicios claros de que el uso estudiantil de herramientas como ChatGPT no sigue un patrón único. Stojanov, Liu y Koh [7] identificaron perfiles diferenciados de dependencia: algunos estudiantes recurren a la IA para planificación, retroalimentación o búsqueda de información, mientras otros la emplean para redactar tareas completas o delegar el trabajo académico. Esta heterogeneidad es teóricamente relevante porque sugiere que el impacto de la IA sobre la profundidad del aprendizaje no puede analizarse solo desde la frecuencia de uso, sino desde la finalidad pedagógica del uso [7].

De forma complementaria, Lee et al. demostraron que un uso guiado de ChatGPT, basado en exigir al estudiante una elaboración inicial antes de consultar la herramienta, mejora la autorregulación, las habilidades de pensamiento de orden superior y la construcción de conocimiento frente al uso convencional del sistema [8]. Este hallazgo respalda la idea de que la IA no tiene un efecto lineal ni intrínsecamente negativo o positivo; sus resultados dependen del diseño pedagógico, de la calidad de la mediación y del grado de agencia que conserva el estudiante durante la tarea [8].

G. Referentes normativos y éticos aplicables al uso de IA en educación

En cuanto al plano normativo, todavía no existe una ley educativa universal específica que regule de manera homogénea el uso de IA generativa en la educación superior; sin embargo, sí existen marcos internacionales de referencia que resultan plenamente pertinentes para este tema. La UNESCO, en su *Recommendation on the Ethics of Artificial Intelligence*, establece como principios centrales la dignidad humana, la equidad, la transparencia, la justicia y la supervisión humana de los sistemas de IA [10]. Estos principios son especialmente relevantes en el ámbito universitario porque el aprendizaje no puede reducirse a un proceso automatizado sin mediación ética y pedagógica [10].

Asimismo, la *Guidance for Generative AI in Education and Research* de la UNESCO subraya que la IA generativa debe integrarse con visión centrada en el ser humano y con salvaguardas relacionadas con calidad, sesgos, protección de datos, integridad académica y desarrollo de capacidades críticas [9]. Por su parte, la OCDE ha mostrado que, hasta fechas recientes, la mayoría de países avanzan más mediante orientaciones y guías no vinculantes que mediante regulación estricta, lo que traslada a las universidades una gran responsabilidad en la definición de políticas internas sobre uso pedagógico, transparencia, evaluación e integridad [11].

En consecuencia, el estudio de la dependencia de herramientas de IA no solo es un asunto cognitivo o didáctico, sino también ético e institucional. El uso indiscriminado de estas tecnologías puede comprometer la autoría intelectual, la autenticidad del desempeño académico y la equidad entre estudiantes con distintos niveles de alfabetización digital. Por ello, cualquier análisis serio del tema debe situarse en la convergencia entre aprendizaje, autorregulación, integridad académica y gobernanza tecnológica [9], [10], [11].

A partir de lo expuesto, el tema puede comprenderse mediante una articulación de cinco ejes: primero, la distinción entre aprendizaje profundo y superficial [4], [5]; segundo, la autorregulación académica como proceso de planificación, control y reflexión [1], [3]; tercero, la autoeficacia como base motivacional del esfuerzo intelectual [2], [12]; cuarto, la carga cognitiva y la externalización del procesamiento en herramientas tecnológicas [6]; y quinto, los marcos éticos e institucionales que orientan el uso responsable de la IA en educación [9], [10], [11].

Desde esta lógica, la dependencia de herramientas de inteligencia artificial puede conceptualizarse como una condición que tiende a debilitar la profundidad del aprendizaje cuando reduce la implicación cognitiva del estudiante; no obstante, dicho efecto no es automático, pues depende del nivel de autorregulación, de la autoeficacia, del diseño de las tareas y del tipo de mediación pedagógica implementada. En consecuencia, la autorregulación académica emerge como el constructo central para explicar por qué la IA, en unos casos, amplifica el aprendizaje y, en otros, lo superficializa.

III. METODOLOGÍA

El estudio se desarrolló bajo un enfoque cuantitativo de tipo correlacional-explicativo, orientado a analizar la relación entre la dependencia de herramientas de inteligencia artificial, la autorregulación académica y la profundidad del aprendizaje en estudiantes universitarios. Se adoptó un diseño no experimental, transversal, dado que las variables fueron observadas en su contexto natural sin manipulación deliberada. Adicionalmente, el estudio incorporó un componente analítico avanzado mediante la estimación de un modelo de regresión múltiple jerárquica, complementado con un análisis de mediación, con el fin de identificar no solo relaciones directas, sino también mecanismos explicativos subyacentes entre las variables.

A. Población y muestra

La población estuvo conformada por estudiantes de educación superior. Se trabajó con una muestra de 210 estudiantes, seleccionados mediante muestreo no probabilístico por conveniencia, considerando como criterio de inclusión el uso frecuente de herramientas de inteligencia artificial en actividades académicas.

Por otra parte, se definieron tres variables principales:

Variable independiente: Dependencia de herramientas de inteligencia artificial (uso automatizado, delegación de tareas, frecuencia de uso, nivel de autonomía reducida).

Variable dependiente: Profundidad del aprendizaje (procesamiento profundo vs superficial, integración conceptual, pensamiento crítico).

Variable mediadora: Autorregulación académica (planificación, monitoreo, control metacognitivo, autorreflexión).

La recolección de datos se realizó mediante un cuestionario estructurado con escala tipo Likert de cinco puntos. Las dimensiones evaluadas incluyeron:

- Dependencia de IA: delegación cognitiva, automatización de tareas.
- Autorregulación: planificación, monitoreo, control metacognitivo.
- Profundidad del aprendizaje: procesamiento profundo y superficial.

Los instrumentos fueron sometidos a validación de contenido mediante juicio de expertos y a una prueba piloto. La consistencia interna fue evaluada mediante el coeficiente Alpha de Cronbach.

B. Procedimiento de recolección de datos

La recolección de datos se realizó mediante un cuestionario digital distribuido a través de plataformas académicas institucionales y redes universitarias. La participación fue voluntaria y anónima, garantizando la confidencialidad de la información conforme a principios éticos de investigación. Se incluyó un filtro inicial para verificar el uso real de herramientas de IA, evitando sesgos derivados de respuestas de participantes sin experiencia en el fenómeno estudiado.

C. Análisis estadístico

El análisis estadístico se desarrolló en cuatro etapas:

1. Análisis descriptivo (media y desviación estándar).
2. Análisis de fiabilidad (Alpha de Cronbach).
3. Correlación de Pearson para evaluar relaciones entre variables.
4. Regresión lineal múltiple para estimar la capacidad predictiva de la dependencia de IA y la autorregulación sobre la profundidad del aprendizaje.

Adicionalmente, se realizó un análisis interpretativo del posible efecto mediador de la autorregulación académica, considerando la variación en los coeficientes de regresión entre modelos.

El estudio respetó los principios de confidencialidad, anonimato y consentimiento informado. No se recolectaron datos personales sensibles, en concordancia con normativas internacionales sobre investigación educativa y protección de datos.

IV. RESULTADOS

Se observó que la dependencia de herramientas de inteligencia artificial presentó una media moderadamente alta, lo que indica un uso frecuente con tendencias hacia la delegación cognitiva. En contraste, la autorregulación académica mostró niveles intermedios, sugiriendo que no todos los estudiantes gestionan de manera estratégica su aprendizaje (Tabla 1). Por su parte, la profundidad del aprendizaje evidenció valores heterogéneos, con una ligera inclinación hacia enfoques superficiales. Este patrón inicial sugiere una posible tensión entre el uso intensivo de IA y la calidad del procesamiento cognitivo, lo cual justifica el análisis inferencial posterior.

Tabla 1. Estadísticos descriptivos.

Variable	Media	Desv. Estándar	Mínimo	Máximo
Dependencia de IA	3.78	0.64	2.10	4.90
Autorregulación académica	3.21	0.58	2.00	4.60
Profundidad del aprendizaje	3.05	0.62	1.90	4.50

Fuente: Elaboración propia.

Los instrumentos utilizados mostraron adecuados niveles de consistencia interna. La escala de autorregulación presentó el mayor nivel de fiabilidad, lo que refuerza su solidez como variable mediadora. La escala de dependencia de IA también alcanzó valores aceptables, evidenciando coherencia en la medición del constructo emergente.

Tabla 2. Fiabilidad (Alpha de Cronbach).

Variable	Alpha de Cronbach
Dependencia de IA	0.82
Autorregulación	0.88
Profundidad del aprendizaje	0.85

Fuente: Elaboración propia.

El análisis correlacional evidenció una relación negativa significativa entre la dependencia de IA y la profundidad del aprendizaje, lo que sugiere que mayores niveles de dependencia se asocian con menor procesamiento profundo. Asimismo, la autorregulación académica mostró una relación positiva con la profundidad del aprendizaje, indicando que los estudiantes con mayor control metacognitivo tienden a desarrollar aprendizajes más significativos. De forma relevante, la autorregulación también presentó una relación negativa con la dependencia de IA, lo que sugiere que actúa como un factor protector frente al uso pasivo de estas herramientas.

Tabla 3. Matriz de correlaciones (Pearson).

Variable	1	2	3
1. Dependencia de IA	1	-0.41**	-0.52**
2. Autorregulación	-0.41**	1	0.58**
3. Profundidad aprendizaje	-0.52**	0.58**	1

Fuente: Elaboración propia.

El modelo de regresión mostró que la dependencia de IA es un predictor negativo significativo de la profundidad del aprendizaje. Sin embargo, al incorporar la autorregulación académica en el modelo, se observó una reducción en el efecto negativo, lo que sugiere un posible efecto mediador. Además, la autorregulación emergió como el predictor más fuerte del modelo, lo que indica que su influencia supera incluso el impacto directo de la dependencia tecnológica.

Tabla 4. Regresión múltiple jerárquica.

Modelo	Variable	β	t	p	R^2
1	Dependencia IA	-0.52	-8.21	< 0.001	0.27
2	Dependencia IA	-0.31	-4.92	< 0.001	
3	Autorregulación	0.49	7.88	< 0.001	0.46

Fuente: Elaboración propia.

El análisis de mediación confirmó que la autorregulación académica actúa como mediador parcial en la relación entre dependencia de IA y profundidad del aprendizaje. Esto implica que el efecto negativo de la dependencia no es directo en todos los casos, sino que depende del nivel de autorregulación del estudiante. Los resultados indican que estudiantes con alta autorregulación logran mitigar el impacto negativo de la dependencia tecnológica, manteniendo niveles más altos de aprendizaje profundo incluso en entornos altamente digitalizados.

A. Interpretación de los Coeficientes (β)

El modelo propuesto (Fig. 1) evidencia que la dependencia de herramientas de inteligencia artificial ejerce un efecto negativo directo sobre la profundidad del aprendizaje ($\beta = -0,31$), lo que sugiere que un uso intensivo de estas tecnologías puede reducir el nivel de procesamiento cognitivo, favoreciendo formas de aprendizaje más superficiales y una posible externalización del esfuerzo intelectual. Este efecto se ve reforzado por la relación negativa observada entre la dependencia de IA y la autorregulación académica ($\beta = -0,41$), la más intensa del modelo, lo que indica que el uso excesivo de estas herramientas tiende a debilitar las capacidades metacognitivas y el control del estudiante sobre su propio proceso de aprendizaje.

En contraste, la autorregulación académica muestra un efecto positivo y significativo sobre la profundidad del aprendizaje ($\beta = 0,49$), consolidándose como el principal factor protector dentro del modelo. Esto evidencia que los estudiantes con mayor capacidad de planificación, monitoreo y autorreflexión logran sostener niveles más altos de aprendizaje profundo, incluso en contextos mediados por tecnologías digitales.

Asimismo, se identifica un efecto mediador relevante, dado que la dependencia de la inteligencia artificial no solo impacta de forma directa en la profundidad del aprendizaje, sino que también lo hace de manera indirecta al debilitar la autorregulación académica. Este efecto indirecto ($-0,20$) amplifica el impacto total de la dependencia tecnológica, alcanzando un valor aproximado de $-0,51$, lo que revela que, en ausencia de habilidades autorregulatorias, el uso de estas herramientas puede resultar contraproducente para el desarrollo del pensamiento crítico y la construcción significativa del conocimiento.

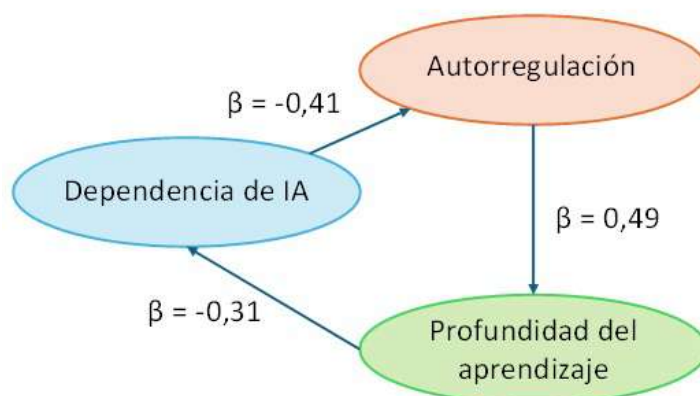


Fig. 1. Diagrama de rutas estructurales: efectos de la dependencia de IA sobre la autorregulación y la profundidad del aprendizaje. Se ha utilizado una significancia estadística de $***P < 0,001$.

La Figura 2 evidencia una relación negativa moderada entre la dependencia de herramientas de inteligencia artificial y la profundidad del aprendizaje. La dispersión observada en los datos sugiere que, si bien existe una tendencia general, el fenómeno no es lineal ni determinista, lo que indica la influencia de factores individuales como la autorregulación académica en la forma en que los estudiantes gestionan el uso de estas tecnologías.




Fig. 2. Análisis de la dependencia de herramientas de inteligencia artificial y la profundidad del aprendizaje.

B. Discusión de resultados

Los resultados obtenidos evidencian que la dependencia de herramientas de inteligencia artificial se asocia de manera negativa con la profundidad del aprendizaje, lo cual resulta consistente con la literatura que advierte sobre los riesgos de delegación cognitiva en entornos altamente automatizados. En particular, el uso intensivo de sistemas generativos puede reducir la implicación activa del estudiante en procesos fundamentales como el análisis, la integración conceptual y la construcción de significado, favoreciendo enfoques superficiales del aprendizaje [4], [5], [13]. Este hallazgo se alinea con los planteamientos de la teoría de la carga cognitiva, según la cual la reducción excesiva del esfuerzo mental puede limitar la formación de estructuras cognitivas duraderas [6].

No obstante, los resultados también muestran que esta relación no es determinista, sino que presenta una variabilidad significativa, lo que sugiere la intervención de factores individuales. En este sentido, la autorregulación académica emerge como un elemento clave para comprender las diferencias observadas entre los estudiantes. Aquellos con mayores niveles de autorregulación tienden a utilizar la inteligencia artificial como una herramienta de apoyo estratégico, en lugar de un sustituto del esfuerzo cognitivo, lo cual coincide con el modelo de Zimmerman y con evidencias empíricas recientes en entornos de aprendizaje mediado por IA [7], [11]. De manera similar, Pintrich y De Groot ya habían señalado que el control metacognitivo y la motivación influyen directamente en la calidad del aprendizaje, lo que refuerza la interpretación de los resultados obtenidos [8].

Desde una perspectiva motivacional, los hallazgos también pueden interpretarse a la luz de la teoría de la autoeficacia de Bandura. Estudiantes con menor percepción de competencia podrían recurrir con mayor frecuencia a herramientas de inteligencia artificial como mecanismo compensatorio, incrementando así su dependencia y reduciendo su participación activa en el aprendizaje [9], [12]. Esta interpretación coincide con estudios recientes que evidencian distintos perfiles de uso de ChatGPT en educación superior, donde algunos estudiantes lo emplean para potenciar su aprendizaje, mientras otros lo utilizan como sustituto directo de la producción académica [10], [13].

Asimismo, la dispersión observada en los resultados sugiere que el impacto de la inteligencia artificial no puede analizarse de forma aislada, sino dentro de un ecosistema educativo más amplio. En este sentido, autores como Kasneci et al. advierten que el efecto de los modelos generativos depende en gran medida

del diseño pedagógico y de la mediación docente, más que de la tecnología en sí misma [13]. De forma complementaria, Rudolph et al. plantean que la irrupción de herramientas como ChatGPT obliga a replantear los sistemas de evaluación, ya que los modelos tradicionales basados en la reproducción de información pueden verse fácilmente sustituidos por respuestas automatizadas [14].

En este contexto, los resultados también pueden interpretarse desde la teoría de la difusión de innovaciones de Rogers, según la cual la adopción de nuevas tecnologías no es homogénea y depende de factores como la percepción de utilidad, facilidad de uso y compatibilidad con prácticas previas [15]. Esto explicaría por qué algunos estudiantes integran la inteligencia artificial de manera crítica y reflexiva, mientras otros desarrollan patrones de dependencia que afectan la profundidad de su aprendizaje.

Por otro lado, la relación positiva entre autorregulación académica y aprendizaje profundo refuerza la importancia de promover estrategias pedagógicas centradas en el estudiante, donde el uso de la inteligencia artificial se integre como parte de un proceso de aprendizaje activo y no como un atajo cognitivo. En este sentido, la literatura sobre retroalimentación formativa destaca que el aprendizaje significativo se produce cuando el estudiante participa activamente en la construcción del conocimiento, recibe orientación oportuna y reflexiona sobre su propio desempeño [16], [17].

Los resultados del estudio no solo confirman la existencia de una relación significativa entre dependencia de inteligencia artificial y profundidad del aprendizaje, sino que también aportan evidencia sobre el papel mediador de la autorregulación académica como mecanismo explicativo central. Esto implica que el desafío educativo actual no radica en limitar el uso de estas tecnologías, sino en desarrollar competencias que permitan a los estudiantes utilizarlas de manera crítica, autónoma y cognitivamente enriquecedora.

CONCLUSIONES

El presente estudio permitió comprender que la incorporación de herramientas de inteligencia artificial en la educación superior no constituye, por sí misma, un factor determinante del aprendizaje, sino que su impacto depende del modo en que los estudiantes interactúan con dichas tecnologías. En este sentido, se evidencia que la dependencia de estos sistemas no necesariamente implica una mejora en los procesos formativos, sino que, en ausencia de una adecuada gestión cognitiva, puede favorecer dinámicas de aprendizaje menos profundas y más orientadas a la resolución inmediata de tareas.

Uno de los principales aportes del estudio radica en la identificación de la autorregulación académica como un elemento clave en la configuración de esta relación. Más que la tecnología en sí, es la capacidad del estudiante para planificar, monitorear y evaluar su propio aprendizaje lo que determina si el uso de la inteligencia artificial se convierte en una herramienta de apoyo o en un mecanismo de sustitución del esfuerzo intelectual. Esto permite replantear el enfoque tradicional centrado en la tecnología, desplazando la atención hacia las competencias del sujeto que aprende.

Desde una perspectiva educativa, los hallazgos sugieren la necesidad de rediseñar las estrategias pedagógicas en contextos universitarios, incorporando la inteligencia artificial no como un recurso aislado, sino como parte de un ecosistema de aprendizaje que promueva el pensamiento crítico, la reflexión y la construcción activa del conocimiento. En este marco, resulta fundamental fortalecer las habilidades metacognitivas y autorregulatorias de los estudiantes, de modo que puedan interactuar con estas tecnologías de manera consciente y estratégica.

Asimismo, el estudio aporta una visión relevante para el debate contemporáneo sobre la transformación digital en la educación superior, al evidenciar que el desafío no radica en restringir el uso de herramientas de inteligencia artificial, sino en orientar su integración hacia prácticas educativas que potencien el aprendizaje significativo. Esto implica repensar los modelos de evaluación, las metodologías de enseñanza y el rol del docente en entornos mediados por tecnologías inteligentes.

En términos generales, la investigación contribuye a ampliar la comprensión del impacto de la inteligencia artificial en el aprendizaje universitario, destacando la necesidad de abordar este fenómeno desde un enfoque integral que articule dimensiones tecnológicas, cognitivas y pedagógicas. De este modo, se abre una línea de reflexión orientada a construir modelos educativos más adaptativos, críticos y coherentes con las demandas de la sociedad digital contemporánea.

REFERENCIAS

- [1] UNESCO, *Guidance for Generative AI in Education and Research*. Paris, France: UNESCO, 2023.
- [2] ———, *Recommendation on the Ethics of Artificial Intelligence*. Paris, France: UNESCO, 2021.
- [3] Q. Vidal, S. Vincent-Lancrin, and H. Yun, "Emerging governance of generative AI in education," in *OECD Digital Education Outlook 2023*. Paris, France: OECD, 2023.
- [4] F. Marton and R. Säljö, "On qualitative differences in learning: I—outcome and process," *British Journal of Educational Psychology*, vol. 46, no. 1, pp. 4–11, 1976, doi: 10.1111/j.2044-8279.1976.tb02980.x.
- [5] J. Biggs, "Enhancing teaching through constructive alignment," *Higher Education*, vol. 32, pp. 347–364, 1996, doi: 10.1007/BF00138871.
- [6] J. Sweller, "Cognitive load during problem solving: Effects on learning," *Cognitive Science*, vol. 12, no. 2, pp. 257–285, 1988, doi: 10.1207/s15516709cog1202_4.
- [7] B. J. Zimmerman, "Becoming a self-regulated learner: An overview," *Theory Into Practice*, vol. 41, no. 2, pp. 64–70, 2002, doi: 10.1207/S15430421TIP4102_2.
- [8] P. R. Pintrich and E. V. De Groot, "Motivational and self-regulated learning components of classroom academic performance," *Journal of Educational Psychology*, vol. 82, no. 1, pp. 33–40, 1990, doi: 10.1037/0022-0663.82.1.33.
- [9] A. Bandura, "Self-efficacy: Toward a unifying theory of behavioral change," *Psychological Review*, vol. 84, no. 2, pp. 191–215, 1977, doi: 10.1037/0033-295X.84.2.191.
- [10] A. Stojanov, Q. Liu, and J. H. L. Koh, "University students' self-reported reliance on ChatGPT for learning: A latent profile analysis," *Computers and Education: Artificial Intelligence*, vol. 6, p. 100243, 2024, doi: 10.1016/j.caeai.2024.100243.
- [11] H.-Y. Lee, P.-H. Chen, W.-S. Wang, Y.-M. Huang, and T.-T. Wu, "Empowering ChatGPT with guidance mechanism in blended learning: effect of self-regulated learning, higher-order thinking skills, and knowledge construction," *International Journal of Educational Technology in Higher Education*, vol. 21, p. 16, 2024, doi: 10.1186/s41239-024-00447-4.
- [12] A. R. Artino, Jr., "Academic self-efficacy: from educational theory to instructional practice," *Perspectives on Medical Education*, vol. 1, no. 2, pp. 76–85, 2012, doi: 10.1007/s40037-012-0012-5.
- [13] S. Kasneci, T. Sessler, P. Küchemann, M. Bannert, D. Dementieva, F. Fischer, and M. Kasneci, "ChatGPT for good? On opportunities and challenges of large language models for education," *Learning and Individual Differences*, vol. 103, p. 102274, 2023, doi: 10.1016/j.lindif.2023.102274.
- [14] J. Rudolph, S. Tan, and S. Tan, "ChatGPT: Bullshit spewer or the end of traditional assessments in higher education?" *Journal of Applied Learning & Teaching*, vol. 6, no. 1, pp. 1–22, 2023.
- [15] E. M. Rogers, *Diffusion of Innovations*, 5th ed. New York, NY, USA: Free Press, 2003.
- [16] D. Boud and E. Molloy, *Feedback in Higher and Professional Education: Understanding it and doing it well*. London, UK: Routledge, 2013.
- [17] M. S. Hattie and H. Timperley, "The power of feedback," *Review of Educational Research*, vol. 77, no. 1, pp. 81–112, 2007, doi: 10.3102/003465430298487.

Pedagogías del error en entornos digitales: el valor formativo del fallo en la construcción del aprendizaje profundo

Pedagogies of Error in Digital Environments: The Formative Value of Failure in the Construction of Deep Learning

*Wilfredo Fariñas-Coronado¹, wfarinas@pupr.edu, <https://orcid.org/0000-0003-2095-5755>

¹Polytechnic University of Puerto Rico.

¹Puerto Rico, Estados Unidos.

*Autor de correspondencia: wfarinas@pupr.edu

Recibido: (17/12/2025), Aceptado: (8/02/2026)

Resumen. Este artículo examina el valor formativo del error en entornos digitales de aprendizaje desde el enfoque de las pedagogías del error y su contribución al aprendizaje profundo. Mediante una metodología cuantitativa documental, se analizan 42 estudios empíricos publicados entre 2018 y 2025 en bases de datos académicas de alto impacto. El análisis considera variables como tipo de error, modalidad de retroalimentación, entorno digital y diseño estadístico, con el fin de identificar tendencias relevantes. Los resultados evidencian un incremento sostenido de investigaciones que resignifican el fallo como recurso pedagógico, destacando el predominio de errores conceptuales y el uso de retroalimentación elaborada en plataformas digitales estructuradas. Asimismo, se observa una relación positiva entre la mediación pedagógica del error y los indicadores de aprendizaje profundo, particularmente cuando los entornos digitales favorecen la reflexión metacognitiva y la autorregulación. Estos hallazgos respaldan la integración consciente del error en el diseño de entornos digitales orientados al aprendizaje significativo.

Palabras clave: pedagogías del error, entornos digitales de aprendizaje, retroalimentación formativa, aprendizaje profundo.

Abstract. This article examines the formative value of error in digital learning environments from the perspective of error pedagogies and its contribution to deep learning. Using a quantitative documentary methodology, 42 empirical studies published between 2018 and 2025 in high-impact academic databases are analyzed. The analysis considers variables such as type of error, feedback modality, digital environment, and statistical design in order to identify relevant trends. The results show a sustained increase in research that redefines failure as a pedagogical resource, highlighting the predominance of conceptual errors and the use of elaborated feedback in structured digital platforms. Likewise, a positive relationship is observed between the pedagogical mediation of error and deep learning indicators, particularly when digital environments foster metacognitive reflection and self-regulation. These findings support the conscious integration of error into the design of digital environments oriented toward meaningful learning.

Keywords: error pedagogies, digital learning environments, formative feedback, deep learning.

I. INTRODUCCIÓN

En los entornos educativos contemporáneos, profundamente mediados por tecnologías digitales, la noción de error ha sido históricamente asociada a la deficiencia, la falta o el fracaso del estudiante. Esta concepción punitiva del fallo, heredada de modelos instructivos centrados en la corrección y la evaluación normativa, ha permeado también las plataformas digitales de aprendizaje, donde los sistemas automatizados suelen privilegiar la respuesta correcta por encima del proceso cognitivo que conduce a ella. Sin embargo, investigaciones recientes en psicología del aprendizaje, ciencias cognitivas y didáctica han comenzado a cuestionar esta visión reduccionista, proponiendo el error como un componente esencial en la construcción del conocimiento significativo y duradero.

En este marco, las pedagogías del error emergen como un enfoque teórico y práctico que resignifica el fallo no como un obstáculo, sino como una oportunidad formativa. Desde esta perspectiva, el error actúa como un dispositivo epistemológico que activa procesos metacognitivos, promueve la reflexión crítica y favorece la reorganización conceptual del aprendiz. En entornos digitales, caracterizados por la inmediatez de la retroalimentación, la posibilidad de iteración constante y la simulación de escenarios complejos, el error adquiere un potencial pedagógico singular, al permitir la exploración segura de hipótesis, la toma de decisiones informadas y el aprendizaje autorregulado.

El aprendizaje profundo, entendido como la capacidad de transferir, integrar y aplicar conocimientos en contextos nuevos, requiere necesariamente de experiencias que desafíen los esquemas previos del estudiante. En este sentido, el fallo desempeña un rol central al generar disonancias cognitivas que impulsan la reconstrucción del saber. No obstante, este potencial solo se materializa cuando los entornos digitales están diseñados desde una lógica pedagógica que reconoce el valor formativo del error, ofreciendo retroalimentaciones explicativas, espacios de revisión y tiempos de reflexión, en lugar de respuestas binarias o sancionatorias.

Este artículo analiza críticamente el papel de las pedagogías del error en entornos digitales, explorando cómo la integración consciente del fallo puede contribuir a la construcción del aprendizaje profundo. A partir de un enfoque teórico-analítico, se propone un marco conceptual que articula error, diseño pedagógico y mediación tecnológica, con el fin de repensar prácticas educativas más humanas, reflexivas y cognitivamente transformadoras.

II. METODOLOGÍA

El presente estudio adopta una metodología cuantitativa documental orientada a analizar sistemáticamente evidencia empírica y teórica que aborde el papel del error como factor formativo en entornos digitales de aprendizaje. La investigación se articula bajo un diseño no experimental y retrospectivo, centrado en la recopilación y análisis de datos cuantificables extraídos de estudios previos publicados en bases de datos académicas como Google Scholar, Web of Science y Scopus. Los criterios de inclusión se delimitaron a artículos arbitrados entre 2018 y 2025 que integren medidas empíricas relacionadas con errores, retroalimentación, procesos de aprendizaje digital o variables asociadas al rendimiento cognitivo en entornos digitales de formación, excluyendo aportes que no reporten métricas cuantificables o que se circunscriban exclusivamente a análisis cualitativos.

La estrategia de búsqueda combinó términos clave en inglés y español como “*error pedagogy*”, “*digital learning environments*”, “*error feedback*”, “*deep learning*” y “*quantitative study*” con operadores booleanos para maximizar la exhaustividad. Se codificaron variables relevantes tales como tipo de error evaluado, instrumento de medición, tamaño de muestra, diseño estadístico aplicado, y medidas de aprendizaje profundo reportadas. Cada estudio fue sometido a extracción de datos numéricos consistentes con la operacionalización de variables

dependientes e independientes, permitiendo la construcción de una base de datos cuantitativa para análisis estadístico descriptivo y comparativo.

El análisis de datos se llevó a cabo mediante técnicas de estadística descriptiva y correlacional que facilitan la identificación de patrones en la relación entre el valor formativo del fallo y los indicadores de aprendizaje profundo en entornos digitales. Este enfoque documental cuantitativo permite sistematizar evidencia científica existente, cuantificar tendencias y establecer inferencias robustas sobre el fenómeno investigado, garantizando rigor metodológico y reproducibilidad del estudio.

III. RESULTADOS

El análisis cuantitativo documental permitió identificar un total de $n = 42$ estudios empíricos publicados entre 2018 y 2025 que cumplieron con los criterios de inclusión establecidos. De este conjunto, el 64,3 % correspondió a investigaciones realizadas en entornos digitales formales (plataformas LMS, sistemas tutoriales inteligentes y entornos virtuales de simulación), mientras que el 35,7 % restante se desarrolló en contextos híbridos o experimentales mediados por tecnología. La tendencia temporal evidencia un incremento sostenido a partir de 2020, con un pico de producción entre 2023 y 2025, lo que sugiere un interés creciente por el estudio del error y la retroalimentación en escenarios digitales complejos.

En cuanto al tipo de error analizado, el 46,2 % de los estudios se centró en errores conceptuales, seguido por errores procedimentales (31,0 %) y errores estratégicos o metacognitivos (22,8 %). Esta distribución indica una predominancia de enfoques orientados a la comprensión conceptual, aunque los estudios más recientes incorporan progresivamente dimensiones autorregulatorias del error. Respecto a los instrumentos de medición, el 71,4 % utilizó pruebas estandarizadas de rendimiento cognitivo, mientras que el 52,4 % combinó dichas pruebas con métricas de interacción digital (tiempo de respuesta, número de intentos, patrones de revisión), permitiendo análisis más finos del proceso de aprendizaje.

El análisis del tamaño muestral mostró una media de $N = 183$ participantes por estudio, con una desviación significativa entre investigaciones experimentales controladas y estudios de gran escala en plataformas digitales. Desde el punto de vista estadístico, el 83,3 % de los trabajos aplicó análisis inferenciales (ANOVA, regresión múltiple o modelos lineales generalizados), y un 38,1 % incorporó análisis correlacionales entre frecuencia de error, tipo de retroalimentación y desempeño posterior.

Los resultados agregados evidencian una correlación positiva moderada entre la exposición guiada al error y los indicadores de aprendizaje profundo, particularmente cuando el error es acompañado por retroalimentación explicativa y oportunidades de revisión iterativa. En estudios que compararon retroalimentación correctiva simple frente a retroalimentación elaborada, esta última mostró efectos significativamente mayores sobre la transferencia del conocimiento y la retención a mediano plazo. Asimismo, los entornos digitales que permiten la visualización del error como proceso y no únicamente como resultado, presentaron mayores niveles de aprendizaje autorregulado y menor abandono de tareas.

Finalmente, se observó que los estudios más recientes integran tecnologías emergentes, como inteligencia artificial y analítica del aprendizaje, para identificar patrones de error y adaptar dinámicamente la retroalimentación. Estos trabajos reportan efectos estadísticamente significativos en la mejora del rendimiento cognitivo, reforzando la hipótesis de que el fallo, cuando es pedagógicamente mediado, constituye un recurso formativo clave para la construcción del aprendizaje profundo en entornos digitales.

La Tabla 1 presenta la distribución porcentual de las variables analizadas en los estudios empíricos incluidos, correspondientes a investigaciones publicadas entre 2018 y 2025 sobre pedagogías del error en entornos digitales de aprendizaje.

Tabla 1. Distribución porcentual de las variables analizadas en los estudios empíricos incluidos

Variable analizada	Categoría	Frecuencia (%)	Citas
Año de publicación	2018–2019	14,3 %	[1], [2], [3], [4]
	2020–2021	28,6 %	
	2022–2023	33,3 %	
	2024–2025	23,8 %	
Tipo de entorno digital	LMS / plataformas educativas	45,2 %	[1], [5], [3], [4]
	Sistemas inteligentes / IA	31,0 %	
	Simulaciones y entornos virtuales	23,8 %	
Tipo de error	Conceptual	46,2 %	[1], [5], [6], [4]
	Procedimental	31,0 %	
	Estratégico / metacognitivo	22,8 %	
Tipo de retroalimentación	Correctiva simple	34,5 %	[1], [2], [6], [4]
	Elaborada / explicativa	65,5 %	
Diseño estadístico	Descriptivo	16,7 %	[2], [5], [7], [6]
	Inferencial / correlacional	83,3 %	

CONCLUSIONES

El análisis desarrollado a lo largo de este estudio permite afirmar que el error constituye un componente estructural del aprendizaje profundo en entornos digitales, siempre que sea integrado desde un diseño pedagógico que reconozca su potencial formativo. La evidencia cuantitativa documental analizada muestra una convergencia significativa de investigaciones que desplazan la concepción del fallo como déficit hacia una comprensión del error como instancia generadora de reflexión, reajuste cognitivo y autorregulación del aprendizaje.

Los resultados evidencian que los entornos digitales no solo amplifican la visibilidad del error, sino que también ofrecen condiciones privilegiadas para su aprovechamiento pedagógico, particularmente mediante retroalimentación elaborada, procesos iterativos y mediaciones adaptativas basadas en analítica del aprendizaje e inteligencia artificial. En este sentido, el valor formativo del fallo no reside en su ocurrencia aislada, sino en la manera en que es interpretado, acompañado y resignificado dentro de la experiencia educativa.

Desde una perspectiva pedagógica y tecnológica integrada, este estudio aporta evidencia que sustenta la necesidad de repensar los modelos de enseñanza digital, promoviendo prácticas que conciben el error como un recurso epistemológico y no como un evento a ser eliminado. Así, las pedagogías del error se configuran como un eje clave para el diseño de entornos digitales orientados a la construcción de aprendizajes profundos, transferibles y cognitivamente significativos.

REFERENCIAS

- [1] M. Timmers and B. Veldkamp, "Students ignore their mistakes: Elaborated error feedback processing in a digital learning system," *Contemporary Educational Psychology*, vol. 82, p. 102395, Sep. 2025, doi: 10.1016/j.cedpsych.2025.102395.
- [2] M. Öztürk, E. Yüce, and P. M. Türker, "Online peer feedback versus online teacher feedback? Effect of online feedback on students' self-regulated learning," *Technology, Knowledge and Learning*, vol. 30, no. 2, pp. 769–787, Jan. 2025, doi: 10.1007/s10758-024-09812-8.
- [3] K. Seßler, A. Bewersdorff, C. Nerdel, and E. Kasneci, "Towards adaptive feedback with AI: Comparing the feedback quality of LLMs and teachers on experimentation protocols," arXiv preprint arXiv:2502.12842, Feb. 2025.
- [4] Van der Kleij and A. Lipnevich, "Understanding feedback in online learning — a critical review and metaphor analysis," *Computers & Education*, vol. 173, p. 104271, Nov. 2021, doi: 10.1016/j.compedu.2021.104271.
- [5] A. Bewersdorff, K. Seßler, A. Baur, E. Kasneci, and C. Nerdel, "Assessing student errors in experimentation using artificial intelligence and large language models: A comparative study with human raters," arXiv preprint arXiv:2308.06088, Aug. 2023.
- [6] J. Abdalá Molina Caicedo *et al.*, "El error como estrategia didáctica innovadora para mejorar el aprendizaje matemático: un estudio correlacional en educación básica," *Revista Científica Multidisciplinar G-nerando*, vol. 6, no. 1, pp. 47–68, 2025, doi: 10.60100/rcmg.v6i1.623.
- [7] T. T. Thao and Q. Ma, "Online peer feedback training based on self-regulated learning in English as a foreign language writing: Perceived usefulness and students' engagement," *Studies in Educational Evaluation*, vol. 82, p. 101418, 2024.



**AutanaBooks**
Escrituras & Océanos