

PLATAFORMAS DIGITALES DE APRENDIZAJE IMPULSADAS POR INTELIGENCIA ARTIFICIAL Y SU DESEMPEÑO EN LA EDUCACIÓN SUPERIOR

ARTIFICIAL INTELLIGENCE-POWERED DIGITAL LEARNING PLATFORMS AND THEIR PERFORMANCE IN HIGHER EDUCATION

Rolly Ramírez-Medina¹ , Josue Zapata-Peña¹ , Darwin Aguilar-Chuquizuta^{1,*} , Eneida Bastidas-Muñoz² 

¹Universidad Nacional de Tumbes, Tumbes, 20009, Perú

²Universidad de Guayaquil, Guayaquil, 090112, Ecuador

*Autor de Correspondencia: daguilar@untumbes.edu.pe

Historial del artículo:

Recibido: 11.09.2025

Revisado: 03.11.2025

Aceptado: 26.12.2025

En línea: 15.01.2026

Palabras clave:

Estudiantes

Aprendizaje

Pedagogía

Tecnología

Inteligencia artificial

Keywords:

Students

Learning

Pedagogy

Technology

Artificial intelligence

Resumen:

El estudio analiza la relación entre el uso de plataformas digitales de aprendizaje impulsadas por Inteligencia Artificial (IA) y el rendimiento académico en la educación superior. Se adoptó un enfoque cuantitativo, con diseño no experimental y alcance descriptivo-correlacional, aplicándose un muestreo censal a 569 estudiantes de una universidad pública peruana durante el período académico 2025-I. La recolección de datos se realizó mediante un cuestionario estructurado de 32 ítems, validado con una confiabilidad ($\alpha > 0.80$). Los resultados evidencian una adopción universal de tecnologías basadas en IA, con el 99.6% de los estudiantes reportando alta accesibilidad y uso frecuente. Solo el 26% alcanza un nivel alto de rendimiento académico, mientras que el 49% se sitúa en un nivel medio y el 25% en un nivel bajo. El análisis inferencial revela que el tipo de herramienta de IA utilizada presenta la relación más fuerte con el rendimiento académico, superando a dimensiones como la frecuencia de uso o la percepción de utilidad. La novedad del estudio radica en demostrar empíricamente que la calidad y pertinencia pedagógica de las herramientas de IA constituyen un factor más determinante que su uso intensivo. Se concluye que la integración efectiva de plataformas impulsadas por IA requiere enfoques pedagógicos estratégicos orientados al fortalecimiento del aprendizaje universitario.

Abstract:

The study analyzes the relationship between the use of digital learning platforms powered by Artificial Intelligence (AI) and academic performance in higher education. A quantitative approach was adopted, with a non-experimental design and descriptive-correlational scope, applying a census sampling to 569 students from a Peruvian public university during the 2025-I academic period. Data collection was carried out using a structured questionnaire with 32 items, validated with a reliability ($\alpha > 0.80$). The results show universal adoption of AI-based technologies, with 99.6% of students reporting high accessibility and frequent use. Only 26% achieve a high level of academic performance, while 49% are at an average level and 25% at a low level. Inferential analysis reveals that the type of AI tool used has the strongest relationship with academic performance, surpassing dimensions such as frequency of use or perceived usefulness. The novelty of the study lies in empirically demonstrating that the quality and pedagogical relevance of AI tools are a more decisive factor than their intensive use. It concludes that the effective integration of AI-driven platforms requires strategic pedagogical approaches aimed at strengthening university learning.

Cómo citar:

R. Ramírez-Medina, J. Zapata-Peña, D. Aguilar-Chuquizuta y E. Bastidas-Muñoz, «Plataformas digitales de aprendizaje impulsadas por inteligencia artificial y su desempeño en la educación superior», *International Journal of Computational Innovations, Intelligent Systems and AI*, vol. 2, n.º 1, pp. 48–69, ene. 2026. doi: [10.64439/cisai.v2i1.32](https://doi.org/10.64439/cisai.v2i1.32)

Este es un artículo de acceso abierto
bajo licencia CC-BY-NC-ND



I. INTRODUCCIÓN

La integración de la IA en la educación superior ha transformado los paradigmas de enseñanza-aprendizaje a nivel global [1]. Las plataformas de aprendizaje adaptativo, potenciadas por algoritmos de aprendizaje automático y procesamiento de lenguaje natural, ajustan dinámicamente contenidos, ritmo y metodologías pedagógicas según las necesidades individuales de cada estudiante [2]. Esta transformación responde a la necesidad de personalizar las experiencias de aprendizaje y mejorar los resultados académicos en contextos de alta heterogeneidad educativa [3]. En esta dirección, hay mucha evidencia empírica que respalda el uso de estas tecnologías. Una revisión sistemática informa que cerca del 40% de las instituciones educativas informan mejoras en procesos de aprendizaje a partir de la implementación de la IA [4]. A su vez, otro estudio de tipo meta-analítico muestra que los sistemas tutoriales inteligentes contribuyen a mejorar el rendimiento académico entre un 15% y un 25% de estudiantes y a aumentar la implicación por el aprendizaje hasta un 40% [5]. En la misma línea, se han presentado resultados de una investigación experimental que muestra mejoras estadísticamente significativas en habilidades cognitivas clave. Por ejemplo, en la resolución de problemas ($M = 65.4$ vs. $M = 72.8$, $p < 0.001$), pensamiento crítico ($M = 68.9$ vs. $M = 74.3$, $p < 0.001$) y razonamiento lógico ($M = 63.2$ vs. $M = 70.1$, $p = 0.001$) [6].

Sin embargo, estos desarrollos están acompañados de amplias brechas digitales que amenazan con profundizar las desigualdades educativas. Mientras que las instituciones de educación superior en países de altos ingresos han podido implementar sistemas completos, las instituciones situadas en países de bajos y medios ingresos todavía se deben enfrentar a limitaciones de infraestructura, de formación, y de recursos institucionales [7]. De forma aún más pronunciada, esta brecha se agudiza en América Latina, donde las desigualdades digitales se incrementaron durante la pandemia de COVID-19 y se acentuaron especialmente en el alumnado de estratos socioeconómicos bajos [8]. Un estudio con 2.882 estudiantes universitarios de distintas instituciones de América Latina ha puesto de manifiesto patrones de desigualdad incluso en aspectos de frecuencia, duración y satisfacción relacionados con el uso de herramientas digitales [9]. Asimismo, los organismos internacionales han puesto de relieve que el uso de la IA en educación no tan solo requiere de infraestructura, sino también de formación en competencias digitales y de políticas institucionales que favorezcan la equidad y la inclusión [10].

Por lo tanto, la investigación empírica en IA y rendimiento ha tenido un gran desarrollo, pero con resultados contradictorios. En un reciente meta-análisis reportan tamaños del efecto grandes en rendimiento académico ($g = 0.554$, $p < 0.05$) [11]. De igual manera, una revisión sistemática indica pros pero también contras, donde se subraya el uso ético dudoso, la resistencia en el profesorado y una dependencia digital excesiva [12]. También se ha reportado que el uso habitual de IA generativa correlaciona negativamente con las habilidades de pensamiento crítico, permitiendo "pereza metacognitiva" que disminuye el compromiso en este tipo de procesos [13]. A su vez, un análisis sobre el uso de ChatGPT reporta mejoras en condición de rendimiento pero esfuerzo mental disminuido, poniendo en ninguna duda los resultados a largo plazo sobre el aprendizaje genuino [14] [15] [16]. Esta evidencia indica que la eficacia de la IA depende de cómo se integre pedagógicamente y las condiciones contextuales de uso.

A pesar del creciente cuerpo de evidencia internacional sobre el uso de la inteligencia artificial en educación, persisten brechas relevantes que justifican nuevas investigaciones. La literatura se ha concentrado mayoritariamente en contextos de Asia, América del Norte y Europa, con una representación aún limitada de realidades latinoamericanas [12], así como en disciplinas STEM, dejando subrepresentados campos como la administración [17]. De igual manera, numerosos estudios priorizan la evaluación de la efectividad técnica de las herramientas de IA, sin incorporar de manera suficiente factores contextuales, socioeconómicos y culturales que condicionan su adopción y uso [18], ni analizar de forma integrada múltiples dimensiones del rendimiento académico asociadas a variables específicas de utilización de IA [19].

Esta situación es especialmente evidente en América Latina, donde la investigación en la educación superior se encuentra en etapas iniciales. En el caso peruano, los estudios existentes refieren patrones fragmentados de utilización, tales como relaciones significativas entre el uso de IA y el aprendizaje cooperativo en estudiantes de ingeniería [20], aplicaciones docentes orientadas a la aportación de textos con retos en la urbanización curricular [21], y correlaciones entre las competencias investigativas y el uso de las herramientas inteligentes [22] [23]. También se pone de manifiesto esta brecha en la escena regional, evidenciándose en la región de Tumbes, Perú, donde la escuela profesional de administración de la Universidad Nacional de Tumbes posee indicadores académicos retadores. Por ejemplo, se estima que el 41% de los alumnos no llegan a la media mínima con lo que pone de manifiesto carencias en habilidades básicas como la escritura académica, la gestión del tiempo y la comprensión lectora. Por tanto, a pesar del desarrollo de entornos de digitalización institucional, el uso del tipo de herramientas basadas en IA todavía no ha partido de la definición de los procesos académicos ni tampoco de la facilitación personalizada mediante tecnologías adaptativas. Así, el presente texto tiene como objetivo el análisis de la influencia que tienen plataformas digitales de aprendizaje por IA sobre el rendimiento académico de los alumnos de educación superior a la vez que se propone un marco de aprendizaje por IA de forma adaptativa en la educación universitaria. En el plano particular, se busca revisar la relación entre el acceso a herramientas por IA, la frecuencia y tipo de uso de este tipo herramientas y la percepción de utilidad, y el rendimiento académico en diferentes dimensiones como son la planificación del estudio o la comprensión del contenido, la resolución de tareas o el logro de resultados. Con ello se intentará aportar evidencias empíricas en la efectividad contextualizada de tecnologías educativas novedosas en contextos marcados por la escasez en recursos y el momento y la brecha digital. Lo que queda de texto se estructura como sigue. En la siguiente sección se presenta el marco metodológico detallando diseño de la investigación, población y muestra, instrumentos de recolección de datos y procedimientos de análisis estadístico. La tercera sección presenta los resultados organizados alrededor de dimensiones del rendimiento académico. La cuarta sección aporta una discusión de los resultados en relación con la literatura existente que identifica implicaciones teóricas y/o prácticas. Por último, la quinta sección presenta las conclusiones, limitaciones y recomendaciones para futuras investigaciones.

II. MÉTODOS

La metodología de la investigación se establece con el propósito de garantizar que se realice de forma precisa y rigurosa, así como para favorecer la transparencia de la información que se considera necesaria para poder reproducir los hallazgos obtenidos en el estudio. En función de naturaleza de la actividad de estudio, el diseño metodológico que se establece, se ajusta a la necesidad de establecer de forma sistemática la relación existente entre el uso de las plataformas de aprendizaje digital donde queda incorporada la inteligencia artificial y el rendimiento académico en la entidad universitaria concreta. Todo ello nos lleva a la posterior formulación de la definición del diseño de la investigación, así como la población y muestra, las variables a estudiar, los instrumentos de medida, los procesos de recogida de datos y análisis estadístico de los datos.

2.1 Diseño metodológico

Este estudio empleó un enfoque cuantitativo y diseño no experimental, de corte transversal para examinar la relación entre las plataformas digitales de aprendizaje impulsadas por inteligencia artificial y el rendimiento académico. La investigación se realizó durante el período académico 2025-I en la Universidad Nacional de Tumbes, Perú. Se adoptó un alcance descriptivo-correlacional para caracterizar los patrones de uso de la IA y establecer la magnitud y dirección de las asociaciones con las dimensiones del rendimiento académico [1] [2]. No se manipularon deliberadamente las variables. Más bien, se observaron en su contexto educativo natural para analizar sus relaciones. La Figura 1 ilustra el marco conceptual y el diseño de investigación empleado en este estudio.




Figura 1. Modelo metodológico para el análisis del rendimiento académico

La figura 1 ilustra sucintamente el diseño metodológico del estudio. En primer lugar, se concreta una población de 569 estudiantes, a la cual se aplica un muestreo censal, lo que implica que la totalidad de los sujetos pasan a ser considerados en el análisis, de ahí que no haya errores de inferencia por muestreo. El instrumento de recolección de datos es un cuestionario, por lo que permite realizar la medición de las variables de estudio a partir de ítems ya definidos y validados. La información que recoge el instrumento es procesada mediante un análisis estadístico de tipo descriptivo-correlacional, que tiene como finalidad, por un lado, caracterizar las variables observadas y, por otro, comprobar las relaciones que existen entre ellas. Por tanto, las flechas bidireccionales indican que el enfoque no se limita a una descripción aislada, sino que busca establecer asociaciones entre el rendimiento académico y las variables analizadas a partir del cuestionario.

2.2 Población y Muestreo

Los participantes fueron 569 estudiantes matriculados en la Escuela Profesional de Administración de la Universidad Nacional de Tumbes durante el semestre académico 2025-I. Para el estudio, utilizamos la información poblacional del sistema integrado de gestión académica, de manera que la información registrada fuera precisa y actual. La población fue de tamaño finito y contaba con características aceptablemente homogéneas y similares en los aspectos de formación académica y en el contexto institucional, el tratamiento para el estudio de la muestra fue el muestreo censal. Por lo tanto, al ser la totalidad de estudiantes matriculados durante el periodo de estudio el objeto de nuestro estudio, no era necesario aplicar técnicas de muestreo probabilístico o no probabilístico. En este sentido, el tratamiento del muestreo censal tiene la ventaja de eliminar el error muestral y permite fortalecer el tema de la validez interna de los resultados, aspecto muy importante en estudios de un enfoque cuantitativo y de alcance descriptivo-correlacional aplicados en contextos educativos.

2.3 Variables de estudio

El estudio analiza dos variables. La primera variable fue, “Inteligencia Artificial” considerada como variable independiente y el “Rendimiento Académico” como variable dependiente. Ambas variables fueron conceptualizadas como constructos multidimensionales y fueron operacionalizadas a partir de dimensiones e indicadores observables o medidos. De este modo, fue posible proceder con su análisis cuantitativo riguroso, correspondiente a un enfoque metodológico muy extendido en el ámbito de la investigación educativa. La variable “Inteligencia Artificial” fue operacionalizada a partir de 4 dimensiones que reflejan las distintas dimensiones de la interacción, uso y percepción de las tecnologías basadas en IA en un contexto académico. La Tabla 1 presenta la operación de esta variable de forma detallada y se presenta la estructura de operacionalización, dimensiones e indicadores.

Tabla 1. Operacionalización de la variable inteligencia artificial

Dimensión	Indicadores
Accesibilidad	Facilidad de acceso a plataformas de IA Conectividad y dispositivos disponibles Nivel de conocimiento previo
Frecuencia de Uso	Uso semanal o diario Tiempo de interacción por sesión Participación en actividades asistidas por IA
Tipo de Herramientas	Uso de chatbots educativos Uso de plataformas automatizadas Aplicación de sistemas de tutoría virtual
Percepción de Utilidad	Utilidad percibida para estudiar Utilidad para resolver tareas Utilidad para mejorar rendimiento académico

A continuación, la definición “rendimiento académico”, considerado como la variable dependiente de tipo multidimensional, al sumar tanto las componentes cognitivas como las actitudinales y el desempeño académico. Su operacionalización la podemos encontrar en la Tabla 2 donde se describen las dimensiones e indicadores que nos servirán para su medición, en consonancia con lo expuesto por la literatura especializada en la materia del rendimiento académico.

Tabla 2. Operacionalización de la variable rendimiento académico

Dimensión	Indicadores
Planificación Académica	Elaboración de cronogramas de estudio Anticipación a fechas de entrega Distribución adecuada del tiempo
Comprensión de Contenidos	Nivel de claridad en la comprensión Interpretación de lecturas Participación en clase
Resolución de Tareas	Cumplimiento de actividades Calidad de las entregas Aplicación práctica de lo aprendido
Logro de Resultados	Calificaciones obtenidas Aprobación de asignaturas Evolución del rendimiento por ciclo

2.4 Instrumentos

Se diseñó un cuestionario estructurado de 32 ítems, distribuidos de manera balanceada entre las dos variables de estudio (16 ítems por variable). Cada enunciado se respondió mediante una escala Likert de cinco categorías, desde “Totalmente en desacuerdo” (1) hasta “Totalmente de acuerdo” (5), conforme a los lineamientos recomendados en la literatura psicométrica para medición de constructos latentes en contextos educativos.

La Tabla 3 presenta el instrumento de medición de la variable “Inteligencia Artificial”, organizada en cuatro dimensiones con 16 ítems que evalúan el compromiso estudiantil con plataformas de IA. La dimensión de accesibilidad (ítems 1-4) examina las condiciones de infraestructura y conocimientos previos; la frecuencia de uso (ítems 5-8) cuantifica la intensidad de interacción con sistemas de IA; el tipo de herramientas (ítems 9-12) identifica las tecnologías específicas empleadas; y la percepción de utilidad (ítems 13-16) evalúa las valoraciones subjetivas sobre los beneficios de la IA para el aprendizaje y organización académica.

Tabla 3. Cuestionario para evaluar la variable inteligencia artificial

Dimensión	Ítem
Accesibilidad	Tengo fácil acceso a plataformas que utilizan IA para mi aprendizaje.
	Cuento con conectividad a internet y dispositivos para acceder a herramientas de IA.
	Tenía conocimientos básicos sobre el uso de IA en educación.
	Las herramientas de IA facilitan la resolución de tareas académicas.
Frecuencia de uso	Utilizo herramientas de IA al menos una vez por semana para fines académicos.
	Dedico más de 30 minutos por sesión a interactuar con sistemas basados en IA.
	Participo regularmente en actividades académicas que incorporan IA.
	Uso frecuentemente herramientas de IA en mi proceso de aprendizaje.
Tipo de herramienta	He utilizado chatbots educativos para resolver dudas académicas.
	Utilizo plataformas automatizadas que corrigen ejercicios o exámenes.
	He interactuado con sistemas de tutoría virtual guiados por IA.
	Percibo que la IA contribuye directamente a mejorar mi rendimiento.
Percepción de utilidad	Me siento motivado(a) a estudiar cuando utilizo herramientas con IA.
	El uso de IA me permite organizar mejor mi tiempo de estudio.
	Las plataformas con IA promueven un aprendizaje autónomo y personalizado.
	Recomendaría el uso de herramientas basadas en IA a compañeros.

La Tabla 4 muestra el instrumento de “Rendimiento Académico”, igualmente estructurado en cuatro dimensiones con 16 ítems. La planificación académica (ítems 1-4) evalúa la capacidad de organización y gestión del tiempo, la comprensión de contenidos (ítems 5-8) mide la profundidad del entendimiento alcanzado, la resolución de tareas (ítems 9-12) examina la calidad y aplicación práctica de conocimientos y el logro de resultados (ítems 13-16) captura indicadores objetivos de desempeño. Ambos instrumentos utilizan una escala Likert de 5 puntos y fueron validados mediante juicio de expertos, alcanzando coeficientes de confiabilidad superiores a 0.70 en todas las dimensiones.

Tabla 4. Cuestionario para evaluar la variable rendimiento académico

Dimensión	Ítem
Planificación académica	Elaboro cronogramas de estudio para organizar mis actividades académicas.
	Me anticipo a las fechas de entrega de trabajos y exámenes.
	Distribuyo adecuadamente mi tiempo entre clases, tareas y estudios.
	Evalúo y ajusto mi planificación académica cuando surge un imprevisto.
Comprensión de contenidos	Comprendo con claridad los contenidos que se abordan en las clases.
	Puedo interpretar adecuadamente los textos y materiales de lectura asignados.
	Participo activamente en clase porque comprendo los temas discutidos.
	Utilizo estrategias para mejorar mi comprensión cuando tengo dificultades.
Resolución de tareas	Cumplo con la entrega de todas las actividades académicas asignadas.
	Las tareas que realizo reflejan calidad y dominio del tema.
	Aplico los conocimientos adquiridos en las tareas y actividades prácticas.
	Reviso y corrijo mis trabajos antes de entregarlos para asegurar su calidad.
Logro de resultados	Obtengo buenas calificaciones en la mayoría de mis asignaturas.
	Apruebo regularmente las materias del semestre sin necesidad de recuperación.
	Mi rendimiento académico ha mejorado progresivamente a lo largo de los ciclos.
	Los resultados que obtengo reflejan mi esfuerzo y aprendizaje.

La validez de contenido se estableció mediante juicio de expertos. Participaron cinco evaluadores con experiencia en tecnología educativa, pedagogía y metodología de investigación, quienes revisaron la pertinencia, claridad y representatividad de los ítems respecto de sus dimensiones teóricas. Posteriormente, se calculó el Coeficiente de Validez de Contenido por ítem. Todos alcanzaron valores superiores a 0.80, lo que evidencia un nivel de validez de contenido y respalda la adecuación semántica y conceptual del instrumento. En cuanto a la confiabilidad se examinó a través de la consistencia interna, empleando el alfa de Cronbach (α). Para ello, una vez recogidas las respuestas del cuestionario, se organizaron los ítems por dimensión (según la matriz de operacionalización), y se estimó α por cada dimensión con base en la covariación entre sus ítems. En términos operativos, el procedimiento se enmarcó en: (1) depuración básica de la base (verificación de valores perdidos y codificación homogénea 1–5), (2) agrupación de ítems por dimensión, (3) cálculo de α para cada grupo y (4) contraste con el umbral psicométrico de referencia ($\alpha \geq 0.70$) para estudios aplicados.

Los resultados se presentan en la Tabla 5, donde se observa que todas las dimensiones superan el criterio mínimo, con valores que oscilan entre 0.823 y 0.883, lo que indica una consistencia interna buena en todas las dimensiones evaluadas. En particular, para la variable “Inteligencia Artificial” se obtuvieron $\alpha=0.831$ (Accesibilidad), $\alpha=0.847$ (Frecuencia de uso), $\alpha=0.823$ (Tipo de herramientas) y $\alpha=0.865$ (Percepción de utilidad). Para, “Rendimiento Académico”, los coeficientes fueron $\alpha=0.842$ (Planificación académica), $\alpha=0.858$ (Comprensión de contenidos), $\alpha=0.871$ (Resolución de tareas) y $\alpha=0.883$ (Logro de resultados). Por tanto, estos hallazgos sustentan que el instrumento presenta estabilidad interna adecuada para el análisis inferencial posterior y reduce el riesgo de error de medición dentro de cada dimensión.

Tabla 5. Coeficientes de confiabilidad de consistencia interna

Variable	Dimensión	Alfa de Cronbach (α)	Decisión
Inteligencia Artificial	Accesibilidad	0.831	Buena
	Frecuencia de Uso	0.847	
	Tipo de Herramientas	0.823	
	Percepción de Utilidad	0.865	
Rendimiento Académico	Planificación Académica	0.842	Buena
	Comprensión de Contenidos	0.858	
	Resolución de Tareas	0.871	
	Logro de Resultados	0.883	

La Tabla 5 se elaboró a partir de las respuestas obtenidas del cuestionario aplicado, las cuales fueron previamente organizadas y codificadas conforme a la escala Likert de cinco puntos. Seguidamente, los ítems se agruparon según la estructura dimensional definida en la operacionalización de las variables, de modo que cada dimensión fue analizada como un constructo independiente integrado únicamente por los ítems que la representan teóricamente. Para cada uno de estos conjuntos se calculó el coeficiente alfa de Cronbach (α) mediante software estadístico SPSS, con el propósito de evaluar el grado de coherencia interna entre los ítems y su capacidad para medir consistentemente el constructo subyacente. La interpretación de los coeficientes se realizó conforme a los criterios psicométricos ampliamente aceptados, adoptándose como referencia un valor mínimo de $\alpha \geq 0.70$. Dado que todas las dimensiones superaron dicho umbral, se concluye que el instrumento presenta una consistencia interna adecuada, razón por la cual los coeficientes fueron clasificados con una confiabilidad buena, respaldando así la solidez de las mediciones reportadas.

2.5 Procedimiento de recolección de datos

La recolección de datos se realizó durante un período de cuatro semanas entre septiembre y octubre de 2025. El equipo de investigación coordinó con áreas directivas para programar sesiones de aplicación del instrumento durante horarios regulares de clase, minimizando la interrupción de actividades académicas mientras se maximizaban las tasas de participación. Los estudiantes fueron informados sobre los objetivos del estudio, la naturaleza voluntaria de su participación, el carácter confidencial de sus respuestas y su derecho a retirarse en cualquier momento sin consecuencias académicas. Se obtuvo el consentimiento informado de todos los participantes antes de la administración del instrumento. Los cuestionarios fueron aplicados en formato físico por tres asistentes de investigación previamente capacitados en técnicas estandarizadas de administración de instrumentos, quienes estuvieron disponibles para resolver dudas procedimentales sin influir en las respuestas de los participantes.

La aplicación se realizó en sesiones supervisadas con grupos de aproximadamente 30-40 estudiantes por aula, con una duración promedio de 20 minutos por sesión. Los participantes completaron los cuestionarios de manera individual para evitar sesgos de deseabilidad social o influencia grupal. Inmediatamente después de la recolección, cada cuestionario fue revisado para verificar su completitud, codificado con un identificador único para garantizar la anonimización, y almacenado en un archivo seguro. Los cuestionarios con más del 10% de datos faltantes (más de 3 ítems sin responder) fueron excluidos del análisis. El conjunto de datos final incluyó respuestas válidas de 542 estudiantes de una población objetivo de 569, alcanzando una tasa de respuesta del 95.3%, la cual supera ampliamente el umbral del 67% reportado como típico en investigación educativa en ciencias de la salud [24] y el 44% promedio documentado para encuestas en investigación académica [25].

2.6 Análisis Estadístico

El análisis de datos se realizó utilizando IBM SPSS Statistics versión 28.0 (IBM Corp., Armonk, NY). El proceso analítico siguió un enfoque secuencial que comprendió análisis descriptivo, evaluación de supuestos estadísticos, análisis de confiabilidad, análisis inferencial y prueba de hipótesis. Se calcularon estadísticos descriptivos para caracterizar la muestra y resumir los patrones de respuesta. Para variables categóricas (sexo, nivel académico) se computaron frecuencias absolutas y porcentajes. Para las variables cuantitativas continuas (puntuaciones de las dimensiones e índices globales de las variables), se calcularon medidas de tendencia central (media aritmética, mediana) y de dispersión (desviación estándar, rango intercuartílico). Estos estadísticos permitieron identificar la distribución de respuestas y detectar posibles valores atípicos. Dado que las pruebas paramétricas requieren el cumplimiento de supuestos de normalidad, se evaluó la distribución de las variables cuantitativas mediante dos aproximaciones complementarias. Primero, se aplicaron las pruebas de normalidad de Kolmogorov-Smirnov (con corrección de significación de Lilliefors) y Shapiro-Wilk, considerándose distribuciones normales aquellas con valores $p > 0.05$ [26]. La prueba de Shapiro-Wilk fue priorizada para la interpretación dado su mayor poder estadístico en muestras pequeñas y medianas [27]. Segundo, se examinaron gráficos Q-Q normales para inspección visual de la normalidad. Como se ha mencionado anteriormente, la consistencia interna de los instrumentos fue evaluada mediante el coeficiente alfa de Cronbach (α) para cada dimensión y para las escalas globales. Se consideraron aceptables valores de $\alpha \geq 0.70$, buenos valores entre 0.80 y 0.89, y excelentes valores ≥ 0.90 [28] [29]. Adicionalmente, se calculó la correlación ítem-total corregida para identificar ítems con correlaciones débiles ($r < 0.30$) que pudieran comprometer la consistencia interna de las dimensiones.

Para examinar las relaciones entre las variables de inteligencia artificial y rendimiento académico, se utilizaron coeficientes de correlación. La selección entre el coeficiente de correlación de Pearson (r) o el coeficiente rho de Spearman (ρ) dependió del cumplimiento de los supuestos de normalidad. Se empleó Pearson para variables con distribución normal bivariada, y Spearman para variables que no cumplieron este supuesto [30]. Los coeficientes de correlación fueron interpretados utilizando criterios empíricos ajustados para investigación educativa: 0.10-0.19 (muy débil), 0.20-0.29 (débil), 0.30-0.49 (moderada), y ≥ 0.50 (fuerte) [31] [32]. La significancia estadística fue evaluada mediante pruebas bilaterales con un nivel de significancia $\alpha = 0.05$, correspondiente a un intervalo de confianza del 95%. En esta misma línea, se contrastaron cuatro hipótesis específicas:

- **H₁:** La accesibilidad de herramientas de IA se relaciona significativamente con la planificación académica de los estudiantes.
- **H₂:** La frecuencia de uso de IA afecta significativamente la comprensión de contenidos académicos.
- **H₃:** El tipo de herramienta de IA utilizada se relaciona significativamente con la capacidad de resolución de tareas académicas.
- **H₄:** La percepción de utilidad de IA influye significativamente en el logro de resultados académicos.

Para cada hipótesis, se estableció la hipótesis nula (H_0 : no existe relación significativa entre las variables) y la hipótesis alternativa (H_1 : existe una relación significativa entre las variables). La decisión de rechazar o no rechazar H_0 se basó en el valor p obtenido: valores $p < 0.05$ condujeron al rechazo de H_0 y proporcionaron evidencia estadística de una relación significativa entre las variables. Adicionalmente a las pruebas de significancia estadística, se calcularon tamaños del efecto para evaluar la magnitud práctica de las relaciones encontradas, complementando así la significancia estadística con información sobre la relevancia sustantiva de los hallazgos [33]. Los datos faltantes, que representaron menos del 3% del total, fueron manejados mediante eliminación por lista, dado que su proporción fue mínima y no se identificaron patrones sistemáticos de pérdida de datos que pudieran introducir sesgos sustanciales en los resultados. Esta aproximación es aceptable cuando los datos faltantes son mínimos y se asume el mecanismo de pérdida completamente al azar [34] [35].

III. RESULTADOS

La presente sección expone los hallazgos obtenidos del proceso de evaluación de las variables inteligencia artificial y rendimiento académico en una muestra de 569 estudiantes de la Escuela Profesional de Administración de la Universidad Nacional de Tumbes durante el año académico 2025. Los resultados se organizan en tres fases. Primero se realiza un análisis descriptivo, que caracteriza el comportamiento y distribución de las variables estudiadas mediante estadística univariada y bivariada. Posteriormente, se describe el análisis inferencial, que examina las relaciones estadísticas planteadas en las hipótesis de investigación a través del coeficiente de correlación de Spearman. Por último, se caracteriza una propuesta que enmarca el proceso y adaptación de plataformas tecnológicas impulsadas en IA con la finalidad de fortalecer el rendimiento académico.

3.1 Accesibilidad a herramientas de inteligencia artificial

El primer objetivo específico buscó determinar la relación entre la accesibilidad de las herramientas de IA y el rendimiento académico de los estudiantes. La accesibilidad fue operacionalizada en base a la disponibilidad técnica, a la facilidad de conexión y al conocimiento de las plataformas que estaban disponibles. Los resultados consignados en la Tabla 6 evidencian que la accesibilidad a las herramientas de inteligencia artificial es prácticamente universal entre los estudiantes evaluados, concentrándose el 99.65% en el nivel alto, siendo marginales los niveles medio y bajo. Este resultado

confirma que las condiciones de acceso tecnológico infraestructura digital, conectividad y disponibilidad de plataformas basadas en IA se encuentran muy consolidadas en el marco universitario con un contexto muy propicio para la presencia de tecnologías digitales avanzadas en los procesos formativos. Sin embargo, al contrastar estos niveles de accesibilidad con el rendimiento académico se puede confirmar que esta disponibilidad tecnológica no se traduce de manera automática en un rendimiento académico elevado. A pesar del acceso casi pleno a herramientas de IA, tan solo un 26% de los estudiantes obtiene un nivel alto de rendimiento y la mayoría de estos se encuentra repartido entre los niveles medio (49%) y bajo (25%). Esta disociación pone de manifiesto que la accesibilidad, a pesar de ser una condición necesaria, no es suficiente para producir importantes mejoras de los resultados académicos.

Tabla 6. Accesibilidad a IA y rendimiento académico

Nivel	Accesibilidad de herramientas de IA			Rendimiento académico	
	Puntuación	Encuestados	%	Encuestados	%
Bajo	De 4 a 9	2	0.35%	145	25%
Medio	De 10 a 14	0	0.00%	277	49%
Alto	De 15 a 20	567	99.65%	147	26%
Total		569	100%	569	100%

Desde una perspectiva analítica, los resultados de la Tabla 6 permiten inferir que la relación entre accesibilidad a herramientas de IA y rendimiento académico se encuentra mediada por el modo en que dichas tecnologías son integradas en las prácticas de aprendizaje. La existencia de altos niveles de acceso, coexistiendo con desempeños académicos mayoritariamente intermedios, demuestra que el potencial de las tecnologías de la información impulsadas por inteligencia artificial aún no es plenamente aprovechado en términos pedagógicos, especialmente en lo referido al desarrollo de competencias cognitivas superiores, aprendizaje autónomo y autorregulación académica. En este sentido, los hallazgos exponen la necesidad de trascender enfoques centrados exclusivamente en la provisión tecnológica y avanzar hacia modelos educativos que promuevan el uso estratégico, reflexivo y formativo de las TIC basadas en IA. La accesibilidad detectada evidencia una oportunidad que debe ser capitalizada mediante orientaciones pedagógicas claras, formación en competencias digitales avanzadas y prácticas didácticas que integren la inteligencia artificial como un recurso para potenciar el aprendizaje significativo, la resolución de problemas y la construcción activa del conocimiento.

3.2 Establecer la incidencia de la frecuencia de uso de la IA en el rendimiento académico

Los resultados que se presentan en la Tabla 7 posibilitan examinar el efecto que tiene la frecuencia de uso de las herramientas de inteligencia artificial en el rendimiento académico de los participantes. La distribución que se aprecia muestra que toda la muestra se encuadra en los niveles medio y alto de frecuencia de uso, lo que denota que la práctica con herramientas de IA ya forma parte de la práctica académica asociada, más allá de ser una práctica ocasionalizada. Sin embargo, cuando se contrasta la frecuencia de uso de las herramientas de IA con los niveles de rendimiento académico, se constata que el uso de las herramientas de IA al tiempo que el rendimiento académico suelen presentar frecuencias elevadas no son garantes de un rendimiento académico elevado. Por el contrario, aun cuando un porcentaje importante de la muestra reporta una frecuencia alta de uso de herramientas de IA, el rendimiento académico sigue presentando sobre todo frecuencias medias, y luego bajas. La frecuencia alta para el rendimiento académico presenta unas frecuencias comparativamente bajas. Esto pone de manifiesto que la alta frecuencia de uso de herramientas de IA no es un determinante lineal de mejora del rendimiento académico.

Tabla 7. Frecuencia de uso de la IA en el rendimiento académico

Nivel	Frecuencia de uso de la IA			Rendimiento académico	
	Puntuación	Encuestados	%	Encuestados	%
Bajo	De 4 a 9	2	0%	145	25%
Medio	De 10 a 14	0	53%	277	49%
Alto	De 15 a 20	567	47%	147	26%
Total		569	100%	569	100%

Desde la perspectiva interpretativa, los resultados indican que la frecuencia de uso, entendida como la repetición o la intensidad de la interacción con las herramientas de IA, adquiere sentido académico sólo si puede establecerse con criterios de pertinencia, profundidad cognitiva y alineación con los objetivos de aprendizaje. Hacer un uso frecuente de la IA, tal y como orienta a la automatización de la tarea o a la mejora del tiempo, puede generar eficiencia operativa, pero no necesariamente traducción de procesos de aprendizaje. Desde este punto de vista, los resultados nos indican que la frecuencia de uso de la inteligencia artificial y por tanto rendimiento académico se da de modo condicionado, dependiendo también del tipo de actividades académicas que las incorporen y del nivel de reflexión que adolece su uso. Así, la frecuencia se nos da como un factor importante, pero no determinante por sí mismo, repitiendo la idea de que la incidencia educativa de la IA se produce más en el que se usa y en para qué se usa antes que en el cuánto.

3.3 Analizar la relación entre el tipo de herramienta de IA empleada y el Rendimiento académico.

La interpretación que proviene de lo expuesto en la Tabla 8 pone de manifiesto los resultados asociados a la clase de herramienta de inteligencia artificial, de manera que a partir de este análisis se puede observar un escenario que tiene una fuerte preponderancia de estudiantes que llevan a cabo tareas académicas con herramientas digitales de mayor funcionalidad, lo que revela que existe una clara preferencia hacia las tecnologías en IA que cuentan con capacidad de automatización, de generación de respuestas complejas y de asistencia cognitiva en el ámbito de diversas tareas de estudio. Es más, la destacada preferencia no se manifiesta en rendimiento académico, con un fuerte uso de las herramientas que han sido ubicadas en el nivel más alto, mientras que las opciones académicas de los estudiantes parecen estar colocadas, en su mayoría, en niveles intermedios y con un porcentaje menor en niveles bajos, lo cual muestra que la utilización de tecnologías más potentes no es un factor suficiente para mejorar el rendimiento académico, de forma que sería importante observar en qué medida se emplean estas herramientas en el proceso educacional.

Tabla 8. Incidencia de tipos de herramienta de IA y el rendimiento académico

Nivel	Tipo de herramienta de IA			Rendimiento académico	
	Puntuación	Encuestados	%	Encuestados	%
Bajo	De 4 a 9	2	0.35%	145	25%
Medio	De 10 a 14	0	0.00%	277	49%
Alto	De 15 a 20	567	99.65%	147	26%
Total		569	100%	569	100%

Desde la mirada de la innovación didáctica, los resultados observados reflejan que el tipo de herramienta de inteligencia artificial utilizada y el rendimiento académico obtenido dependerán de la funcionalidad de la herramienta de la inteligencia artificial y de la práctica de actividades de aprendizaje y estudio. Las soluciones tecnológicas de la inteligencia artificial proporcionan amplias opciones para el análisis, la síntesis y la toma de decisiones de los alumnos. Aun así, su utilidad académica queda reducida si su uso se plantea como una herramienta para la simplificación de tareas

o para obtener resultados. Así, los datos muestran que el potencial de las herramientas de la inteligencia artificial sólo se activa si se articulan con planteamientos pedagógicos donde hay una reflexión, un razonamiento y una construcción activa del conocimiento, por lo que dan sentido a su papel en el aprendizaje universitario.

3.4 La percepción de utilidad de la IA influye en el logro del rendimiento académico

Los datos expuestos en la Tabla 8 posibilitan el análisis de la función desempeñada por la apreciación subjetiva de la utilidad de las herramientas de inteligencia artificial en lo que respecta a la obtención del rendimiento académico. Dicha distribución exhibió una casi plena concentración del alumnado entre los niveles altos de percepción de utilidad, lo que supone que la gran mayoría de los estudiantes reconoce a la IA como un recurso operativo y motivante para el progreso de sus actividades académicas. No obstante, dicho reconocimiento generalizado no se traduce de manera proporcional en los resultados académicos obtenidos, ya que el rendimiento continúa en niveles intermedios, en su gran mayoría, y bajos. Dicho esto, este asunto pone en evidencia que una buena apreciación de la tecnología, aunque sea positiva, no actúa automáticamente como un eslabón directo del rendimiento académico.

Tabla 9. Incidencia de la percepción de utilidad de IA y el rendimiento académico

Nivel	Percepción de utilidad de la IA			Rendimiento académico	
	Puntuación	Encuestados	%	Encuestados	%
Bajo	De 4 a 9	2	0.35%	145	25%
Medio	De 10 a 14	0	0.00%	277	49%
Alto	De 15 a 20	567	99.65%	147	26%
Total		569	100%	569	100%

Desde una óptica orientada en torno a la adopción tecnológica en los contextos de educación, los resultados de la Tabla 9 constatan que el efecto que ejerce la percepción de la utilidad se encuentra mediado por la manera en que esta se traduce en prácticas concretas de como aprender. Reconocer la conveniencia funcional de la inteligencia artificial no asegura, ni de lejos, alcanzar un uso estratégico asociado al rendimiento académico. De esta forma, los resultados obtenidos evidencian que la percepción favorable debe ir acompañada de competencias para integrar la tecnología en procesos que requieran razonamiento crítico, toma de decisiones y reflexión académica. La utilidad percibida adquiere por tanto una verdadera relevancia en la medida en que se convierte en un uso estratégico y cognitivamente determinado de las herramientas de IA dentro del proceso educativo.

3.5 Análisis inferencial y contrastación de hipótesis

Los resultados del análisis inferencial que se ofrecen en la Tabla 10 muestran la existencia de relaciones significativas en el uso de la inteligencia artificial y el rendimiento de los estudiantes universitarios, encontrando relaciones positivas de nivel moderado entre la accesibilidad y la frecuencia del uso de herramientas de IA con el rendimiento, ambos con coeficientes de correlación idénticos y magnitudes de significancia muy altas, indicando que la disponibilidad de recursos tecnológicos y su uso recurrente se encontraría asociado a un buen rendimiento de forma constante (pero no determinante), y la existencia de significación estadística asegura que estas relaciones no se producen al azar, sino que explican patrones sistemáticos de comportamiento académico en la población que se estudia.

Tabla 10. Relación entre el uso de inteligencia artificial y rendimiento académico

Dimensión	Coficiente (q)	Valor p	Interpretación
Accesibilidad de herramientas de IA	0.544**	<.001	Correlación positiva baja pero significativa
Frecuencia de uso de IA	0.544**	<.001	
Tipo de herramienta de IA	0.836**	<.001	
Percepción de utilidad de IA	0.314**	<.001	

Un aspecto a tener en cuenta de los análisis que se han expuesto en la Tabla 10, representa la correlación positiva muy alta de la categoría de la herramienta de inteligencia artificial utilizada, que acumula el coeficiente más alto entre las dimensiones que fueron objeto de estimación. Este hallazgo indica que las características y las funcionalidades propias de las soluciones tecnológicas utilizadas han tenido una influencia diferente sobre el rendimiento académico. En cambio, la percepción de utilidad de la IA, a pesar de que la correlación es significativa, es menos intensa que en el caso anterior, lo que implica que la valoración subjetiva de la tecnología no conlleva necesariamente mejoras del propio rendimiento. De este modo, estos resultados corroboran las hipótesis planteadas y nos permiten establecer que el rendimiento académico asociado a la inteligencia artificial depende de diferentes dimensiones tecnológicas y que cada una de ellas va a tener una influencia distinta en función de la forma en que esté integrado en el proceso educativo.

3.6 Marco cíclico para la integración adaptativa de plataformas impulsadas por IA

En este apartado se comparte una propuesta para poner en marcha la formalización del proceso de implementación e incorporación de plataformas tecnológicas concretadas por la inteligencia artificial en el entorno universitario, a fin de consolidarse de manera sostenida en el mejoramiento del rendimiento académico. La Figura 2, presenta la propuesta que se basa en un enfoque cíclico de mejora continua, en el que la inteligencia artificial no se asocia de una forma aislada, sino como una parte dinámica integrada en el interior de la planificación, la ejecución, la evaluación y el ajuste de los procesos formativos.




Figura 2. Marco adaptativo de aprendizaje impulsado por IA en contextos universitarios

En este sentido, el aprendizaje impulsado por IA aparece como el hilo que une tecnología, pedagogía y toma de decisiones académicas, dado que permite dar respuesta de manera flexible a las verdaderas exigencias del alumnado y la situación de la institución. En la primera fase, la de Planificar, se orienta a la definición estratégica de la práctica de los usos de tecnologías de IA. En esta fase se establecen principios éticos, se delimitan métricas de éxito académico y se elige aquellas técnicas de inteligencia artificial que mejor funcionan, a tenor de los objetivos pedagógicos. No sólo se tiene en cuenta la viabilidad técnica en esta planificación, sino también la coherencia curricular y el impacto en relación con los procesos de aprendizaje, asegurando de siempre que el uso de la tecnología desemboque en determinados fines formativos, claros y medibles. Mientras que en la etapa de Desarrollar la preocupación está en la utilización de las plataformas potenciadas por IA. En este momento se consideran prioritarias las competencias digitales de docentes y alumnos, la inclusión de sistemas inteligentes en los entornos virtuales de aprendizaje, y se elaboran contenidos adaptativos que responden al ritmo y estilos de aprendizaje de los usuarios. También se incluyen modelos de “machine learning” que permiten realizar una experiencia mucho más personalizada y a la vez propician una interacción más activa y significativa con los contenidos académicos.

Luego, la etapa de Verificar es también fundamental para el control y la retroalimentación. En esta etapa se verifica el uso de las plataformas, se mide el impacto real de la inteligencia artificial en el rendimiento académico y se audita el proceso de integración de la tecnología. A parte, el análisis de datos de carácter educativo y la recopilación de buenas prácticas permiten detectar fortalezas y limitaciones, y también posibles oportunidades de mejora, así como controlar que el uso de la inteligencia artificial sea coherente con los objetivos académicos establecidos. Por último, la etapa de Actuar está centrada en la toma de decisiones correctivas y evolutivas. Gracias a los resultados obtenidos se redefinen los contenidos académicos, se cambian las políticas institucionales, se escalan las prácticas tecnológicas que han producido los mejores resultados en el aprendizaje. Esta etapa consagra el carácter adaptativo del modelo, por el cual las soluciones en IA son principalmente sostenibles, y a la vez son también dinámicas a la hora de cómo pueden incrementar el rendimiento académico a partir del marco de la innovación educativa.

IV. DISCUSIÓN

Los hallazgos del presente estudio revelan un panorama multidimensional respecto a la integración de plataformas digitales de aprendizaje impulsadas por inteligencia artificial en la educación superior. La adopción prácticamente universal de estas tecnologías entre los estudiantes de la Escuela Profesional de Administración de la Universidad Nacional de Tumbes (95.6% de los participantes reportan su uso regular) constituye un indicador tangible de la transformación del ecosistema educativo contemporáneo. Este fenómeno se alinea con las tendencias globales documentadas en la literatura reciente, donde las instituciones de educación superior experimentan una acelerada digitalización impulsada tanto por la disponibilidad tecnológica como por las expectativas estudiantiles de experiencias de aprendizaje más personalizadas y flexibles [36] [37]. No obstante, la presente investigación evidencia que la mera disponibilidad o frecuencia de uso de herramientas de IA no se traduce automáticamente en mejoras sustantivas del rendimiento académico, lo cual plantea interrogantes fundamentales sobre los mecanismos mediadores que determinan la efectividad de estas tecnologías educativas.

La paradoja observada entre la elevada accesibilidad a herramientas de IA (99.65% de los estudiantes reportan acceso de nivel alto) y la distribución moderada del rendimiento académico (solo 26% alcanza nivel alto) constituye uno de los hallazgos más significativos de esta investigación. Esta disociación entre acceso tecnológico y logro académico refuerza los argumentos teóricos que distinguen entre disponibilidad instrumental y apropiación pedagógica efectiva de las tecnologías

educativas [38] [39]. La literatura contemporánea sobre sistemas adaptativos de aprendizaje sugiere que la efectividad de las plataformas de IA depende críticamente de variables contextuales que incluyen la alfabetización digital del estudiantado, la calidad del diseño instruccional que acompaña la implementación tecnológica, y el nivel de acompañamiento pedagógico proporcionado por los docentes [36]. En contextos de educación superior latinoamericana, donde persisten brechas significativas en competencias digitales avanzadas y donde los marcos institucionales para la integración de IA educativa aún se encuentran en desarrollo, resulta comprensible que el acceso tecnológico por sí solo no garantice transformaciones sustantivas en los resultados de aprendizaje. Este fenómeno expone la necesidad de políticas institucionales que trasciendan la provisión de infraestructura tecnológica y avancen hacia modelos integrales que contemplen la formación docente, el desarrollo de competencias digitales estudiantiles, y el diseño de estrategias pedagógicas específicamente orientadas a maximizar el potencial de las herramientas de IA disponibles.

La correlación positiva moderada ($q = 0.544$, $p < .001$) entre la frecuencia de uso de herramientas de IA y el rendimiento académico requiere una interpretación matizada que distinga entre uso intensivo y uso estratégico. Aunque una proporción considerable de estudiantes reporta emplear estas tecnologías semanalmente (57.6%) o incluso diariamente (18.8%), la magnitud moderada del coeficiente de correlación muestra que la frecuencia, en ausencia de otras variables mediadoras, ejerce una influencia limitada sobre el desempeño académico. Esta observación encuentra respaldo en una investigación reciente sobre aprendizaje adaptativo, las cuales demuestran que la efectividad de las plataformas de IA depende fundamentalmente de la naturaleza cognitiva de las actividades realizadas mediante estas herramientas [40]. Específicamente, existe evidencia empírica que indica que el uso de IA para tareas de orden cognitivo inferior—tales como la búsqueda automatizada de información o la generación mecánica de respuestas—aporta beneficios limitados al aprendizaje profundo, mientras que su empleo para actividades que demandan procesamiento metacognitivo, análisis crítico o síntesis conceptual se asocia con mejoras más sustantivas en el rendimiento académico [41]. Por tanto, estudiantes con alta frecuencia de uso no necesariamente exhiben rendimiento superior lo que evidencia la presencia de patrones de uso superficial, donde las herramientas se emplean primordialmente como facilitadores de eficiencia temporal en lugar de instrumentos para el desarrollo de competencias cognitivas avanzadas. Esta interpretación se ve reforzada por las preocupaciones expresadas por los propios estudiantes respecto a la posibilidad de dependencia excesiva de la tecnología (16.5%) y el deterioro del pensamiento crítico (16.5%), lo cual indica una conciencia emergente sobre los riesgos asociados al uso no reflexivo de la IA en contextos educativos.

En este sentido, el hallazgo más robusto del presente estudio reside en la correlación positiva alta ($q = 0.836$, $p < .001$) entre el tipo de herramienta de IA empleada y el rendimiento académico, la cual representa el coeficiente más elevado entre todas las dimensiones analizadas. Este resultado posee implicaciones teóricas y prácticas de considerable relevancia, dado que demuestra empíricamente que la sofisticación funcional y la pertinencia pedagógica de las herramientas tecnológicas constituyen determinantes más poderosos del desempeño académico que la accesibilidad o frecuencia de uso. Por otro lado, la literatura reciente sobre sistemas inteligentes de tutoría y plataformas de aprendizaje adaptativo corrobora estos hallazgos, documentando que las tecnologías de IA que incorporan algoritmos y modelos de personalización avanzada, retroalimentación adaptativa en tiempo real, y capacidades de análisis del aprendizaje del estudiante generan efectos significativamente más pronunciados sobre los resultados educativos en comparación con herramientas de funcionalidad básica [36] [42]. De igual manera una investigación desarrollada en contextos de educación superior ha demostrado que sistemas de tutoría inteligente basados en modelos de conocimiento del estudiante pueden mejorar el rendimiento académico en porcentajes

que oscilan entre 30% y 54% en comparación con métodos tradicionales, particularmente cuando estas tecnologías se diseñan para promover procesos metacognitivos y habilidades de autorregulación del aprendizaje [43]. En esta línea, el estudio extiende estos hallazgos al contexto latinoamericano, demostrando que estudiantes universitarios que emplean herramientas avanzadas—tales como asistentes virtuales contextuales, sistemas de análisis predictivo del rendimiento, o plataformas de generación de contenido educativo personalizado—exhiben desempeños académicos sustancialmente superiores a aquellos que se limitan al uso de aplicaciones básicas o de propósito general. Esta diferenciación instrumental demuestra que las instituciones de educación superior deberían priorizar no solamente la provisión de acceso tecnológico, sino fundamentalmente la orientación estratégica hacia herramientas de mayor calidad pedagógica y la formación de competencias para su utilización efectiva.

En esta misma dirección, la marcada influencia del tipo de herramienta sobre el rendimiento académico encuentra explicación en los fundamentos teóricos del aprendizaje personalizado y la cognición distribuida. Las plataformas de IA de mayor sofisticación no se limitan a ofrecer información o automatizar procesos rutinarios, sino que operan como medios cognitivos que apoyan procesos de pensamiento de orden superior mediante la estructuración de tareas complejas, la provisión de retroalimentación formativa específica, y la adaptación dinámica del nivel de dificultad y los contenidos en función del progreso individual del estudiante [40] [44]. También una estudio aborda el aprendizaje adaptativo y documentan que estas funcionalidades avanzadas resultan particularmente efectivas para promover la autorregulación del aprendizaje, una competencia metacognitiva que se asocia consistentemente con mejor desempeño académico, mayor motivación intrínseca, y reducción de la deserción estudiantil [45]. No obstante, la literatura también advierte sobre riesgos potenciales asociados al uso de herramientas avanzadas de IA, particularmente el fenómeno de “descarga cognitiva”, mediante el cual los estudiantes pueden desarrollar dependencia excesiva de las capacidades computacionales de estas tecnologías, delegando procesos de pensamiento que deberían desarrollar autónomamente [41]. Un estudio reciente sobre el uso de ChatGPT en educación superior encontró que, si bien la herramienta mejora el rendimiento inmediato en tareas específicas, puede generar simultáneamente “pereza metacognitiva”, reduciendo el esfuerzo mental invertido por los estudiantes y potencialmente comprometiendo el aprendizaje a largo plazo [46]. Estos resultados evidencian la importancia de diseñar intervenciones pedagógicas que equilibren el potencial de las herramientas avanzadas de IA con estrategias explícitas para promover el pensamiento crítico, la reflexión metacognitiva y la autonomía intelectual del estudiantado.

Por otro lado, la correlación positiva baja pero significativa ($\rho = 0.314$, $p < .001$) entre la percepción de utilidad de la IA y el rendimiento académico constituye un hallazgo que requiere interpretación cuidadosa desde marcos teóricos de aceptación tecnológica. Aunque 83.5% de los estudiantes consideran que la IA mejora su eficiencia en el aprendizaje, y una proporción similar (82.4%) percibe efectos positivos sobre su desempeño académico, la magnitud del coeficiente de correlación sugiere que estas creencias ejercen influencia limitada sobre los resultados reales de aprendizaje. Esta aparente disociación entre percepción y desempeño efectivo se alinea con investigaciones previas que demuestran que la utilidad percibida, si bien constituye un predictor robusto de la intención de uso tecnológico, no necesariamente se traduce en mejoras objetivas del rendimiento académico en ausencia de patrones efectivos de utilización [47]. En este mismo camino, el modelo de aceptación tecnológica y su extensión, el modelo unificado de aceptación y uso de la tecnológica, exponen que la percepción de utilidad influye sobre los resultados educativos de manera mediada por variables comportamentales concretas, tales como la intensidad del uso, la diversidad de aplicaciones empleadas, y la integración de la tecnología en estrategias metacognitivas de aprendizaje [48]. Por

tanto, resultados del estudio demuestran que, en el contexto analizado, las actitudes favorables hacia la IA predisponen a los estudiantes hacia la adopción tecnológica pero no garantizan per se el desarrollo de competencias para su uso estratégico. Esta interpretación se ve reforzada por el hecho de que la percepción mayoritariamente positiva coexiste con preocupaciones significativas respecto a la precisión de la información generada por IA (48.2%) y el riesgo de dependencia tecnológica (16.5%), lo cual evidencia una conciencia creciente entre los estudiantes sobre la brecha entre el potencial teórico y los resultados prácticos de estas herramientas.

Asimismo, las preocupaciones expresadas por los estudiantes respecto al uso de IA en educación revelan una comprensión emergente de los riesgos asociados a la integración acrítica de estas tecnologías. La inquietud predominante sobre la posibilidad de recibir respuestas incorrectas o imprecisas (48.2%) refleja una problemática ampliamente documentada en la literatura sobre modelos de lenguaje de gran escala, los cuales, a pesar de su sofisticación técnica, son susceptibles a generar “alucinaciones”—esto es, contenidos que parecen plausibles pero carecen de fundamento fáctico o contienen errores significativos [49]. De igual forma, un reciente trabajo ha demostrado que estudiantes que confían excesivamente en la precisión de sistemas como ChatGPT sin validar críticamente sus respuestas pueden incorporar información errónea en sus trabajos académicos, comprometiendo así la calidad de su aprendizaje y el desarrollo de competencias de evaluación crítica de fuentes [50]. Este fenómeno resulta particularmente problemático en contextos donde los estudiantes carecen de formación explícita en literacidad digital avanzada, incluyendo habilidades para verificar información, identificar sesgos algorítmicos, y evaluar la confiabilidad de contenidos generados por IA. Por otra parte, las preocupaciones sobre el deterioro del pensamiento crítico y la dependencia tecnológica encuentran sustento en evidencia empírica reciente que documenta efectos potencialmente adversos del uso frecuente de IA generativa sobre el desarrollo de habilidades metacognitivas. De igual manera, un estudio experimental demostró que estudiantes que emplean ChatGPT de manera habitual exhiben desempeños significativamente inferiores en tareas que demandan pensamiento crítico, siendo la descarga cognitiva el mecanismo mediador de este efecto negativo [51]. Estas observaciones subrayan la necesidad de desarrollar marcos pedagógicos que orienten el uso responsable y reflexivo de la IA, promoviendo simultáneamente su potencial para el aprendizaje personalizado y la mitigación de riesgos asociados a su adopción acrítica.

Los hallazgos del estudio poseen implicaciones sustantivas para el diseño de políticas institucionales orientadas a la integración efectiva de plataformas digitales impulsadas por IA en la educación superior. En primer término, los resultados evidencian que las intervenciones centradas exclusivamente en la provisión de acceso tecnológico resultan insuficientes para generar transformaciones significativas en el rendimiento académico. Las instituciones universitarias deben evolucionar hacia modelos integrales de innovación educativa que contemplen simultáneamente:

- La formación docente en pedagogías digitales y diseño instruccional mediado por IA.
- El desarrollo sistemático de competencias de literacidad digital avanzada entre los estudiantes, incluyendo habilidades para el uso crítico y estratégico de herramientas de IA
- La selección e implementación de plataformas tecnológicas que privilegien funcionalidades pedagógicamente relevantes, tales como personalización adaptativa, retroalimentación formativa, y analíticas de aprendizaje.
- El establecimiento de marcos éticos y regulatorios que aborden cuestiones de privacidad de datos, transparencia algorítmica, y equidad en el acceso a tecnologías educativas avanzadas.

Para complementar lo antes expuesto, una investigación reciente sobre IA en educación superior señala que las instituciones que adoptan enfoques sistémicos y pedagógicamente fundamentados

logran mejores resultados que aquellas que implementan tecnologías de manera fragmentaria o exclusivamente orientada por consideraciones de eficiencia administrativa [52]. En segundo término, el hallazgo de que el tipo de herramienta constituye el predictor más robusto del rendimiento académico expone que las inversiones institucionales deberían priorizarse hacia la adquisición de plataformas de mayor calidad pedagógica, aun cuando esto implique costos superiores o procesos de implementación más complejos. Asimismo, la literatura sobre retorno de inversión en tecnología educativa documenta que sistemas adaptativos de aprendizaje de alta calidad pueden generar mejoras en la retención estudiantil, reducción de tasas de reprobación, y acortamiento de tiempos de titulación que justifican ampliamente los costos asociados a su implementación [53].

Por último, el marco cíclico de integración adaptativa de plataformas impulsadas por IA propuesto en este estudio—estructurado en las fases de Planificar, Desarrollar, Verificar y Actuar—constituye una contribución metodológica orientada a sistematizar la innovación educativa mediada por tecnología en contextos universitarios. Este modelo se fundamenta en principios de mejora continua derivados de enfoques de gestión de calidad y se alinea con recomendaciones internacionales sobre implementación responsable de IA en educación, tales como las directrices de la UNESCO sobre IA y educación abierta. La fase de planificación enfatiza la importancia de establecer objetivos pedagógicos claros, criterios éticos explícitos, y métricas de éxito académico definidas a priori, evitando así implementaciones tecnológicas desarticuladas de los propósitos formativos institucionales. La fase de desarrollo no solo responde a la componente técnica de llevar a cabo las plataformas, sino que también tiene que ver, sobre todo, con los procesos de formación del profesorado y el desarrollo de competencias del alumnado, los cuales son fundamentales para la buena utilización de las tecnologías. La fase de verificación considera procesos de evaluación continua del impacto en el aprendizaje, tanto a partir de métricas cuantitativas (rendimiento académico, tasas de retención), como de indicadores cualitativos (satisfacción del alumnado, percepción del profesorado, calidad de las experiencias de aprendizaje, etc.). Por ello, la fase de la acción asegura que los resultados de la verificación informen las decisiones de mejorar, escalar o rediseñar las intervenciones tecnológicas. Las futuras investigaciones deberían evaluar la efectividad de este modelo, mediante estudios que relaten una evaluación continua y su impacto en resultados de aprendizaje a medio y largo plazo, así como su viabilidad en diferentes extremos institucionales y disciplinares. Es prioritario también desarrollar investigación que trate los efectos diferenciales de las plataformas de IA sobre diferentes poblaciones estudiantiles (considerando variables como nivel socioeconómico, sexo, etnia, modalidad de estudio, etc.) para asegurar que contribuyan a la equidad educativa, en lugar de reforzar desigualdades preexistentes.

V. CONCLUSIONES

Los resultados revelan que la introducción de plataformas de aprendizaje digital soportadas por inteligencia artificial está profundamente arraigada en términos de acceso y uso. Sin embargo, su efecto sobre el rendimiento académico no sigue una lógica automática y lineal. Los resultados indican que la disponibilidad de dispositivos tecnológicos e incluso la cantidad de veces que se usaron herramientas de inteligencia artificial no tienen un peso importante en el rendimiento académico obtenido, desnudando la existencia de factores mediadores vinculados a la calidad del uso y a su integración pedagógica. Así, la inteligencia artificial se presenta como un recurso con posibilidades “extendibles” en el mundo educativo, siendo su efecto el resultado de una interrelación entre el tipo de uso que se le da y la vinculación con prácticas didácticas vinculadas al desarrollo de competencias cognitivas y de autogestión del aprendizaje.

A su vez, el análisis inferencial corrobora que el tipo de herramienta de inteligencia artificial utilizada es la variable de mayor capacidad explicativa del rendimiento académico, superando variables como la accesibilidad, la frecuencia de uso y la percepción de utilidad. Por ello no todas las tecnologías basadas en IA son capaces de hacer el mismo tipo de impacto educativo y de que su valor académico reside en la pertinencia funcional y pedagógica de las plataformas íntegras a las que se tienen acceso. Por tanto, el uso de la inteligencia artificial en la educación superior debe tener como telón de fondo modelos institucionales que promuevan la selección de herramientas adecuadas, que incluyan el acompañamiento pedagógico y la mejora continua, asegurando así que la innovación tecnológica tenga un efecto claro y duradero sobre el fortalecimiento de la educación universitaria.

Contribución de los autores:

Todos los autores contribuyeron igualmente en la concepción, el diseño del estudio, la recogida y el análisis de los datos, la redacción del estudio, así como en su revisión.

Agradecimientos:

Se expresa un profundo reconocimiento a la Universidad Nacional de Tumbes por el apoyo brindado.

Financiamiento:

El estudio ha sido autofinanciado por los autores.

Declaración de consentimiento informado:

Los participantes otorgaron su consentimiento informado de manera voluntaria antes de su participación en el estudio.

Declaración de disponibilidad de datos:

Los datos que respaldan los resultados de este estudio están disponibles previa solicitud razonable al autor correspondiente.

Conflictos de intereses:

No existen conflictos de intereses.

Declaración de uso de IA:

No se utilizó ninguna herramienta de IA. El contenido académico es responsabilidad exclusiva del autor.

REFERENCIAS

- [1] L. Chen, P. Chen, and Z. Lin, "Artificial Intelligence in Education: A Review," *IEEE Access*, vol. 8, pp. 75264–75278, 2020. <https://doi.org/10.1109/ACCESS.2020.2988510>
- [2] E. Du Plooy, D. Casteleijn, and D. Franzsen, "Personalized adaptive learning in higher education: A scoping review of key characteristics and impact on academic performance and engagement," *Heliyon*, vol. 10, no. 21, p. e39630, Nov. 2024. <https://doi.org/10.1016/j.heliyon.2024.e39630>
- [3] I. M. Castillo-Martínez, D. Flores-Bueno, S. M. Gómez-Puente, and V. O. Vite-León, "AI in higher education: a systematic literature review," *Front. Educ.*, vol. 9, p. 1391485, Aug. 2024. <https://doi.org/10.3389/educ.2024.1391485>
- [4] K. Bayly-Castaneda, M.-S. Ramirez-Montoya, and A. Morita-Alexander, "Crafting personalized learning paths with AI for lifelong learning: a systematic literature review," *Front. Educ.*, vol. 9, p. 1424386, Aug. 2024. <https://doi.org/10.3389/educ.2024.1424386>
- [5] F. Naseer, M. N. Khan, M. Tahir, A. Addas, and S. M. H. Aejaz, "Integrating deep learning techniques for personalized learning pathways in higher education," *Heliyon*, vol. 10, no. 11, p. e32628, Jun. 2024. <https://doi.org/10.1016/j.heliyon.2024.e32628>
- [6] A. Létourneau, M. Deslandes Martineau, P. Charland, J. A. Karran, J. Boasen, and P. M. Léger, "A systematic review of AI-driven intelligent tutoring systems (ITS) in K-12 education," *npj Sci. Learn.*, vol. 10, no. 1, p. 29, May 2025. <https://doi.org/10.1038/s41539-025-00320-7>

- [7] Y. Assefa, M. M. Gebremeskel, B. T. Moges, S. A. Tilwani, and Y. A. Azmera, "Rethinking the digital divide and associated educational in(equity) in higher education in the context of developing countries: the social justice perspective," *IJILT*, vol. 42, no. 1, pp. 15–32, Jan. 2025. <https://doi.org/10.1108/IJILT-03-2024-0058>
- [8] A. Ancheta-Arrabal, C. Pulido-Montes, and V. Carvajal-Mardones, "Gender Digital Divide and Education in Latin America: A Literature Review," *Education Sciences*, vol. 11, no. 12, p. 804, Dec. 2021. <https://doi.org/10.3390/educsci11120804>
- [9] J. García-Martín and J.-N. García-Sánchez, "The Digital Divide of Know-How and Use of Digital Technologies in Higher Education: The Case of a College in Latin America in the COVID-19 Era," *IJERPH*, vol. 19, no. 6, p. 3358, Mar. 2022. <https://doi.org/10.3390/ijerph19063358>
- [10] H. U. Rahiman and R. Kodikal, "Revolutionizing education: Artificial intelligence empowered learning in higher education," *Cogent Education*, vol. 11, no. 1, p. 2293431, Dec. 2024. <https://doi.org/10.1080/2331186X.2023.2293431>
- [11] L. Sun and L. Zhou, "Does Generative Artificial Intelligence Improve the Academic Achievement of College Students? A Meta-Analysis," *Journal of Educational Computing Research*, vol. 62, no. 7, pp. 1676–1713, Dec. 2024. <https://doi.org/10.1177/07356331241277937>
- [12] J. Garzón, E. Patiño, and C. Marulanda, "Systematic Review of Artificial Intelligence in Education: Trends, Benefits, and Challenges," *MTI*, vol. 9, no. 8, p. 84, Aug. 2025. <https://doi.org/10.3390/mti9080084>
- [13] K.-J. Laak and J. Aru, "AI and personalized learning: bridging the gap with modern educational goals," Mar. 21, 2025, *arXiv*: arXiv:2404.02798. <https://doi.org/10.48550/arXiv.2404.02798>
- [14] D. Palal, S. Ghonge, V. Jadav, and H. Rathod, "ChatGPT: A Double-Edged Sword?," *Health Serv Insights*, vol. 16, p. 11786329231174338, Jan. 2023. <https://doi.org/10.1177/11786329231174338>
- [15] N. Abdallah, R. Katmah, K. Khalaf, and H. F. Jelinek, "Systematic review of ChatGPT in higher education: Navigating impact on learning, wellbeing, and collaboration," *Social Sciences & Humanities Open*, vol. 12, p. 101866, 2025. <https://doi.org/10.1016/j.ssaho.2025.101866>
- [16] M. A. Adarkwah, S. A. Badu, E. A. Osei, E. Adu-Gyamfi, J. Odame, and K. Schneider, "ChatGPT in healthcare education: a double-edged sword of trends, challenges, and opportunities," *Discov Educ*, vol. 4, no. 1, p. 14, Jan. 2025. <https://doi.org/10.1007/s44217-024-00393-3>
- [17] I. García-Martínez, J. M. Fernández-Batanero, J. Fernández-Cerero, and S. P. León, "Analysing the Impact of Artificial Intelligence and Computational Sciences on Student Performance: Systematic Review and Meta-analysis," *J. New Approaches Educ. Res.*, vol. 12, no. 1, pp. 171–197, Jan. 2023. <https://doi.org/10.7821/naer.2023.1.1240>
- [18] Y. Assefa, M. M. Gebremeskel, B. T. Moges, S. A. Tilwani, and Y. A. Azmera, "Rethinking the digital divide and associated educational in(equity) in higher education in the context of developing countries: the social justice perspective," *IJILT*, vol. 42, no. 1, pp. 15–32, Jan. 2025. <https://doi.org/10.1108/IJILT-03-2024-0058>
- [19] K. (Kai L. Hon, "Generative AI in Higher Education: A Systematic Review of Its Effects on Learning Outcomes and Academic Performance," *Journal of Educational Technology Systems*, p. 00472395251400089, Nov. 2025. <https://doi.org/10.1177/00472395251400089>
- [20] V. N. Acosta Pastor and W. H. Carcausto Calla, "Inteligencia artificial y aprendizaje cooperativo en estudiantes universitarios," Jul. 24, 2024, *Zenodo*. <https://doi.org/10.5281/ZENODO.12812908>
- [21] R. E. Cruz-Avalos, T. D. R. Merino-Salazar, S. K. Quiroz-Quiroz, and F. K. Cruz-Quiroz, "Uso Inteligencia Artificial en Estudiantes Educación Superior Pedagógica," *RTED*, vol. 18, no. 2, pp. 311–323, Nov. 2025. <https://doi.org/10.37843/rted.v18i2.721>
- [22] J. E. Carhuaricra Espinoza, R. R. Cornejo Flores, J. S. Gora Chamorro, C. Cornejo Flores, and E. E. Nina Cuchillo, "Competencias Investigativas e Inteligencia Artificial en Estudiantes de una Universidad Privada en Lima, Perú," *Ciencia Latina*, vol. 8, no. 4, pp. 10785–10804, Sep. 2024. https://doi.org/10.37811/cl_rcm.v8i4.13223
- [23] J. H. Delgado Romero, J. Vigil Rimarachin, and J. Gaspar Pérez, "Competencias cibernéticas y habilidades investigativas: claves para la transformación educativa en universitarios de la región San Martín, Perú," *Desafíos*, vol. 16, no. 2, Jul. 2025. <https://doi.org/10.37711/desafios.2025.16.2.4>
- [24] A. B. Wilson et al., "Survey response rates in health sciences education research: A 10-year meta-analysis," *Anatomical Sciences Ed*, vol. 17, no. 1, pp. 11–23, Jan. 2024. <https://doi.org/10.1002/ase.2345>
- [25] M.-J. Wu, K. Zhao, and F. Fils-Aime, "Response rates of online surveys in published research: A meta-analysis," *Computers in Human Behavior Reports*, vol. 7, p. 100206, Aug. 2022. <https://doi.org/10.1016/j.chbr.2022.100206>
- [26] A. Ghasemi and S. Zahediasl, "Normality Tests for Statistical Analysis: A Guide for Non-Statisticians," *Int J Endocrinol Metab*, vol. 10, no. 2, pp. 486–489, Dec. 2012. <https://doi.org/10.5812/ijem.3505>

- [27] P. Mishra, C. Pandey, U. Singh, A. Gupta, C. Sahu, and A. Keshri, "Descriptive statistics and normality tests for statistical data," *Ann Card Anaesth*, vol. 22, no. 1, p. 67, 2019. https://doi.org/10.4103/aca.ACA_157_18
- [28] K. S. Taber, "The Use of Cronbach's Alpha When Developing and Reporting Research Instruments in Science Education," *Res Sci Educ*, vol. 48, no. 6, pp. 1273–1296, Dec. 2018. <https://doi.org/10.1007/s11165-016-9602-2>
- [29] Y. F. Zakariya, "Cronbach's alpha in mathematics education research: Its appropriateness, overuse, and alternatives in estimating scale reliability," *Front. Psychol.*, vol. 13, p. 1074430, Dec. 2022. <https://doi.org/10.3389/fpsyg.2022.1074430>
- [30] J. Hauke and T. Kossowski, "Comparison of Values of Pearson's and Spearman's Correlation Coefficients on the Same Sets of Data," *Quaestiones Geographicae*, vol. 30, no. 2, pp. 87–93, Jun. 2011. <https://doi.org/10.2478/v10117-011-0021-1>
- [31] C. R. Brydges, "Effect Size Guidelines, Sample Size Calculations, and Statistical Power in Gerontology," *Innovation in Aging*, vol. 3, no. 4, p. igz036, Aug. 2019. <https://doi.org/10.1093/geroni/igz036>
- [32] I. S. H. Alwahaibi, D. A. M. Al-Hadabi, and H. A. T. Al-Kharousi, "Cohen's criteria for interpreting practical significance indicators: A critical study," *CJES*, vol. 15, no. 2, pp. 246–258, Apr. 2020. <https://doi.org/10.18844/cjes.v15i2.4624>
- [33] J. P. A. Ioannidis, "Why Most Published Research Findings Are False," *PLoS Med*, vol. 2, no. 8, p. e124, Aug. 2005. <https://doi.org/10.1371/journal.pmed.0020124>
- [34] F. Huang and B. Keller, "Working with missing data in large-scale assessments," *Large-scale Assess Educ*, vol. 13, no. 1, p. 13, Apr. 2025. <https://doi.org/10.1186/s40536-025-00248-9>
- [35] P. Schober and T. R. Vetter, "Missing Data and Imputation Methods," *Anesthesia & Analgesia*, vol. 131, no. 5, pp. 1419–1420, Nov. 2020. <https://doi.org/10.1213/ANE.0000000000005068>
- [36] Hariyanto, F. X. D. Kristianingsih, and R. Maharani, "Artificial intelligence in adaptive education: a systematic review of techniques for personalized learning," *Discov Educ*, vol. 4, no. 1, p. 458, Oct. 2025. <https://doi.org/10.1007/s44217-025-00908-6>
- [37] A. M. Vieriu and G. Petrea, "The Impact of Artificial Intelligence (AI) on Students' Academic Development," *Education Sciences*, vol. 15, no. 3, p. 343, Mar. 2025. <https://doi.org/10.3390/educsci15030343>
- [38] H. A. Hamzah, M. S. Abu Seman, and M. Ahmed, "The impact of artificial intelligence in enhancing online learning platform effectiveness in higher education," *Information Development*, vol. 41, no. 3, pp. 794–810, Sep. 2025. <https://doi.org/10.1177/02666669251315842>
- [39] W. Strielkowski, V. Grebennikova, A. Lisovskiy, G. Rakhimova, and T. Vasileva, "AI-driven adaptive learning for sustainable educational transformation," *Sustainable Development*, vol. 33, no. 2, pp. 1921–1947, Apr. 2025. <https://doi.org/10.1002/sd.3221>
- [40] I. Molenaar, "The concept of hybrid human-AI regulation: Exemplifying how to support young learners' self-regulated learning," *Computers and Education: Artificial Intelligence*, vol. 3, p. 100070, 2022. <https://doi.org/10.1016/j.caeai.2022.100070>
- [41] S. Maral, N. Naycı, H. Bilmez, E. İ. Erdemir, and S. A. Satici, "Problematic ChatGPT Use Scale: AI-Human Collaboration or Unraveling the Dark Side of ChatGPT," *Int J Ment Health Addiction*, Jun. 2025. <https://doi.org/10.1007/s11469-025-01509-y>
- [42] S. Maghsudi, A. Lan, J. Xu, and M. Van Der Schaar, "Personalized Education in the Artificial Intelligence Era: What to Expect Next," *IEEE Signal Process. Mag.*, vol. 38, no. 3, pp. 37–50, May 2021. <https://doi.org/10.1109/MSP.2021.3055032>
- [43] E. Farrow, J. Moore, and D. Gašević, "Ordering Effects in a Role-Based Scaffolding Intervention for Asynchronous Online Discussions," in *Artificial Intelligence in Education*, vol. 12748, I. Roll, D. McNamara, S. Sosnovsky, R. Luckin, and V. Dimitrova, Eds., in Lecture Notes in Computer Science, vol. 12748, Cham: Springer International Publishing, 2021, pp. 125–136. https://doi.org/10.1007/978-3-030-78292-4_11
- [44] C. Dignath and M. V. J. Veenman, "The Role of Direct Strategy Instruction and Indirect Activation of Self-Regulated Learning—Evidence from Classroom Observation Studies," *Educ Psychol Rev*, vol. 33, no. 2, pp. 489–533, Jun. 2021. <https://doi.org/10.1007/s10648-020-09534-0>
- [45] X. Li, F. Ouyang, and W. Chen, "Examining the effect of a genetic algorithm-enabled grouping method on collaborative performances, processes, and perceptions," *J Comput High Educ*, vol. 34, no. 3, pp. 790–819, Dec. 2022. <https://doi.org/10.1007/s12528-022-09321-6>
- [46] J. Wang and W. Fan, "The effect of ChatGPT on students' learning performance, learning perception, and higher-order thinking: insights from a meta-analysis," *Humanit Soc Sci Commun*, vol. 12, no. 1, p. 621, May 2025. <https://doi.org/10.1057/s41599-025-04787-y>

- [47] S. Freire, C. Roçadas, J. Pipa, and C. Aguiar, "Classroom social networks, students' peer-related social experiences and sense of belonging: The specific case of students with SEN," *British Educational Res J*, vol. 50, no. 4, pp. 1617–1635, Aug. 2024. <https://doi.org/10.1002/berj.3989>
- [48] C.-H. Liu, Y.-T. Chen, S. Kittikowit, T. Hongsuchon, and Y.-J. Chen, "Using Unified Theory of Acceptance and Use of Technology to Evaluate the Impact of a Mobile Payment App on the Shopping Intention and Usage Behavior of Middle-Aged Customers," *Front. Psychol.*, vol. 13, p. 830842, Mar. 2022. <https://doi.org/10.3389/fpsyg.2022.830842>
- [49] G. Cooper, "Examining Science Education in ChatGPT: An Exploratory Study of Generative Artificial Intelligence," *J Sci Educ Technol*, vol. 32, no. 3, pp. 444–452, Jun. 2023. <https://doi.org/10.1007/s10956-023-10039-y>
- [50] E. Levring Jäghagen, T. De Lange, G. Torgersen, A. Møystad, and J. Ahlqvist, "The use of post-exam feedback in oral radiology: A survey study of dental and dental hygienist schools in Europe," *Eur J Dental Education*, vol. 27, no. 4, pp. 1048–1052, Nov. 2023. <https://doi.org/10.1111/eje.12897>
- [51] M. Gerlich, "Public Anxieties About AI: Implications for Corporate Strategy and Societal Impact," *Administrative Sciences*, vol. 14, no. 11, p. 288, Nov. 2024. <https://doi.org/10.3390/admsci14110288>
- [52] K. Ahmad et al., "Data-Driven Artificial Intelligence in Education: A Comprehensive Review," *IEEE Trans. Learning Technol.*, vol. 17, pp. 12–31, 2024. <https://doi.org/10.1109/TLT.2023.3314610>
- [53] T. Cavanagh, B. Chen, R. A. M. Lahcen, and J. Paradiso, "Constructing a Design Framework and Pedagogical Approach for Adaptive Learning in Higher Education: A Practitioner's Perspective," *IRRODL*, vol. 21, no. 1, pp. 172–196, Jan. 2020. <https://doi.org/10.19173/irrodl.v21i1.4557>