

Transformaciones educativas en la era digital: El rol mediador del aprendizaje inteligente en el rendimiento académico de estudiantes universitarios

Educational Transformations in the Digital Age: The Mediating Role of Smart Learning in the Academic Performance of University Students

Lismer Y. Laura-Pumaleque*

e-mail: llaurap@unsa.edu.pe

Universidad Nacional de San Agustín de Arequipa, Peru.

Dino F. Cuti-Saico

e-mail: dcutis@unsa.edu.pe

Universidad Nacional de San Agustín de Arequipa, Peru.

Maria. F. Mendoza

e-mail: mmendozav@unsa.edu.pe

Universidad Nacional de San Agustín de Arequipa, Peru.

Kristhian P. Medina

e-mail: kmedinag@unsa.edu.pe

Universidad Nacional de San Agustín de Arequipa, Peru.

Miller E. Vargas

e-mail: mvargasv@unsa.edu.pe

Universidad Nacional de San Agustín de Arequipa, Peru.

Resumen: El avance de la tecnología está redefiniendo plenamente la educación a nivel mundial, dejando atrás las formas tradicionales de enseñanza y aprendizaje. Este estudio tiene como objetivo analizar el rol mediador del aprendizaje inteligente en la relación entre la inteligencia artificial (IA) y las redes sociales (RS) en el rendimiento académico (RA) de estudiantes universitarios. Con dicha finalidad, se aplicó un enfoque cuantitativo, transversal, no experimental y de alcance explicativo, encuestando a 426 estudiantes. Se utilizó AFE para evaluar la calidad de los constructos y se elaboró un modelo causal mediante PLS-SEM, confirmando las hipótesis con la técnica del *bootstrapping*. Los resultados manifiestan que el aprendizaje inteligente actúa como mediador significativo y positivo entre la inteligencia artificial y las redes sociales en

el rendimiento académico. Además, la IA y las RS tienen efectos directos positivos, aunque la influencia de las RS es en menor grado. A pesar de las ventajas significativas, el éxito de la integración de tecnologías como la IA y las RS en la educación depende de un uso moderado y consciente. Es importante fomentar habilidades adaptativas y crear entornos educativos que impulsen el uso estratégico de las herramientas digitales como parte de la revolución en la enseñanza tradicional.

Palabras clave: Inteligencia artificial, redes sociales, rendimiento académico, aprendizaje inteligente, teoría del aprendizaje social.

Abstract: Technological advances are completely redefining education worldwide, leaving traditional forms of teaching and learning behind. This study aims to analyze the mediating role of intelligent learning in the relationship between artificial intelligence (AI) and social networks (SN) in the academic performance (AP) of university students. To this end, a quantitative, cross-sectional, non-experimental, and explanatory approach was applied, surveying 426 students. AFE was used to evaluate the quality of the constructs, and a causal model was developed using PLS-SEM, confirming the hypotheses with the bootstrapping technique. The results show that intelligent learning acts as a significant and positive mediator between artificial intelligence and social media in academic performance. In addition, AI and SM have direct positive effects, although the influence of SM is to a lesser degree. Despite the significant advantages, the successful integration of technologies such as AI and SM in education depends on moderate and conscious use. It is important to foster adaptive skills and create educational environments that promote the strategic use of digital tools as part of the revolution in traditional teaching.

Keywords: Artificial Intelligence, Social Networks, Academic Performance, Intelligent Learning, Social Learning Theory.

Received: 06-07-2025

Accepted: 28-11-2025

1. Introducción

En la historia actual de la educación, la transición de las prácticas clásicas a los espacios enriquecidos por la tecnología inteligente supone una transformación radical, cambiando por completo la manera en que se imparte y se adquiere el conocimiento. Como menciona Jimbo-Santana et al. (2023), la inteligencia artificial (IA) se usa para llevar a cabo proyecciones precisas sobre el desempeño, adecuar el material educacional de acuerdo al método de aprendizaje de cada persona y ofrecer evaluación personalizada de manera instantánea. Gracias a la atención personalizada, acompañada de respuestas rápidas y el acceso a una gran cantidad de recursos, las estructuras de IA apoyan a los alumnos a resolver problemas y a maximizar resultados en el proceso educativo (Sánchez-Reina et al., 2023). Mientras tanto, las redes sociales (RS) permiten que los estudiantes comunicarse con sus docentes, obtener datos y revisarlos cuando lo necesiten, haciendo de este recurso una herramienta clave para el análisis de información y la solución de dificultades (Shafiq y Parveen, 2023). La integración efectiva en la educación de la IA y las RS, requiere una comprensión profunda por parte de las autoridades, educadores y desarrolladores de plataformas digitales, puesto que nos ofrece la posibilidad de personalizar el aprendizaje y lograr un mejor rendimiento académico.

Una nueva investigación publicada por IBM en Latinoamérica da cuenta que la adopción de Inteligencia Artificial en el Perú es superior al 59% de la media en Sudamérica. Además, el 57% de los trabajadores mencionan que adoptan la IA en el Perú en su trabajo (ANDINA, 2025). Asimismo, mientras que muchos países latinoamericanos están explorando la legislación sobre IA, el Perú no solo ha presentado el mayor número de proyectos de ley relacionados con la IA, 17 de los 79 identificados, sino que también es el único país con leyes sobre IA en vigor: la Ley 31814, que fomenta la IA para el progreso

nacional, y la Ley 32082, que regula el uso de la IA en las funciones consulares (Smart y Montori, 2025). Sin embargo, la escasez de personal con habilidades y conocimientos necesarios para adoptar la IA constituye la principal dificultad para llevar a cabo dicha implementación (IBM Latinoamérica, 2024). Si bien se tiene la iniciativa de fortalecer estas tecnologías emergentes, las normas no son claras con los principales desafíos de la IA y lo consideran desde perspectivas generales.

En este sentido, el aprendizaje inteligente, se constituye como el mediador perfecto entre la adopción de IA, RS y rendimiento académico. Tal y como indican Sisalima et al. (2024), a partir de un análisis bibliométrico, la personalización del aprendizaje gestionado por IA es potenciada cuando el estudiante desarrolla habilidades de metacognición y autocontrol. Algo similar concluyen Bolaño-García y Duarte-Acosta (2023), quienes sostienen que los entornos adaptativos de IA favorecen en gran medida el rendimiento académico únicamente si el estudiante posee estrategias cognitivas y motivacionales adecuadas. El papel mediador del aprendizaje inteligente entre la IA, RS y rendimiento académico de los estudiantes en entornos universitarios está todavía menos investigado (Dekker et al., 2020; Shahzad et al., 2024).

El objetivo es analizar el rol mediador del aprendizaje inteligente en la relación de la inteligencia artificial y las redes sociales en el rendimiento académico de estudiantes universitarios. Con dicha finalidad, se acoge la teoría del aprendizaje social de Bandura (SLT), para explorar nuevas formas de aprendizaje y enseñanza en un contexto de desarrollo de tecnologías innovadoras. Se plantea un modelo de ecuaciones estructurales PLS-SEM que integra la IA, RS, AIN y el RA, lo que permite evaluar efectos directos e indirectos que existen en el modelo. A diferencia de investigaciones anteriores que han abordado la IA o las RS de manera separada, este trabajo investiga su relación en conjunto, destacando la función mediadora del AIN, incluyendo variables de control como, edad, género y uso de internet con finalidad académica, abordando una falta en la literatura actual. Asimismo, este estudio proporcionará información empírica sobre cómo los estudiantes pueden utilizar la tecnología digital de manera efectiva, mejorando su rendimiento académico; además, actuará como prueba para las instituciones al crear programas que fortalezcan las habilidades en aprendizaje inteligente. Dada la rápida digitalización en la educación, comprender estas relaciones es esencial, mejorando la calidad del proceso educativo y la efectividad de las innovaciones tecnológicas en la educación superior.

El documento se organiza de la siguiente forma. Luego de esta introducción, la sección 2 abarca la fundamentación teórica y la formulación de hipótesis, seguida por una explicación del método de investigación en la sección 3. Después, la sección 4 sintetiza los análisis estadísticos y los hallazgos logrados a través de PLS-SEM. Finalmente, nuestra investigación examina las conclusiones más relevantes que surgen de los resultados del estudio. También se ofrecen recomendaciones para los líderes educacionales con el propósito de guiar las decisiones futuras sobre las estrategias de enseñanza y aprendizaje para potenciar el rendimiento académico.

2. Fundamentación teórica y proposición de hipótesis

2.1. Teoría del aprendizaje social

Como lo desarrolla Bandura (1978), el aprendizaje nace de la observación de determinadas acciones y su posterior imitación. Es decir, que la adquisición de conocimientos

y habilidades se da a través del análisis de las acciones de los demás, lo que determina la repetición o evitación de ciertas actividades (Nadeem, 2024). Asimismo, aquel tipo de interacción se ve influenciado por factores cognitivos, conductuales y ambientales que desempeñan un papel fundamental orientando la conducta de un individuo (Chereau y Meschi, 2022). Además, Bahn (2001) destaca al contexto social de intercambio como un elemento primordial en la Teoría del Aprendizaje Social, lo que resulta importante para el sector educativo debido a la constante interacción entre estudiantes y docentes.

Esta teoría resulta relevante puesto que la SLT considera a la autoeficacia como uno de sus principales componentes claves, la cual se encuentra estrechamente relacionada con un adecuado rendimiento académico (Rosales-Ronquillo y Hernández-Jáquez, 2020). Además, las redes sociales con su diseño interactivo y funciones sofisticadas, permiten la observación de las actividades de otros usuarios y la búsqueda activa de información, lo que facilita el proceso de aprendizaje (Pang y Yang, 2024). En palabras de Pang y Zhang (2024), la SLT facilita la comprensión de las conexiones afectivas de los estudiantes en este tipo de plataformas. De la misma manera, la inteligencia artificial se encuentra vinculada a la teoría, ya que permite la mejora del aprendizaje y la promoción de la participación mediante experiencias educativas personalizadas y adaptables (Naser et al., 2015). Según Ray (2023) la presencia de herramientas de IA generativa, como ChatGPT, requiere un análisis detallado acerca de su posible influencia en el rendimiento escolar y la estabilidad emocional de los estudiantes. De hecho, este recurso tecnológico tiene la habilidad de operar como extensiones de las redes sociales y como orientaciones personalizadas, lo que puede tener un impacto significativo en el aprendizaje y en la salud mental (Shahzad et al., 2024).

2.2. Rendimiento académico

Whelan, Islam y Brooks (2020) señalan que el rendimiento académico es el grado de logro positivo que un estudiante alcanza en sus estudios pre profesionales, este es evaluado mediante la calidad y cantidad del tiempo de estudio, el cumplimiento de metas personales, y el aprovechamiento de oportunidades importantes para el desarrollo estudiantil. Por otro lado, Hailu et al. (2024) lo definen como el nivel alcanzado por un estudiante en sus metas académicas fijadas en un corto o largo plazo, este proceso es medido por instrumentos como el promedio ponderado y la evaluación continua. Por ende, el rendimiento académico es un constructo que adquiere valores cuantitativos y cualitativos en relación a lo aprendido por un estudiante durante su proceso educativo (Navarro, 2016).

2.3. Aprendizaje inteligente

El aprendizaje inteligente (AIN) es catalogado como el proceso eficiente, motivador y personal de aprendizaje de conocimientos y adquisición de habilidades basado en el uso de tecnologías inteligentes (Zang, Kim y Dong, 2022). Adicionalmente, este tipo de aprendizaje detecta la situación, el contexto, las necesidades de aprendizaje y el estilo del estudiante (García-Peñalvo et al., 2020). La integración de la inteligencia artificial y las redes sociales redefine la educación convencional, al disponer de experiencias de aprendizaje más complejas, lo que consigue un mejor rendimiento académico en los estudiantes (Popescu, 2014). Por ello, el aprendizaje inteligente brinda acceso a materiales didácticos, herramientas de colaboración y feedback adaptados a cada estudiante. Del mismo modo, el uso de la inteligencia artificial adaptativa para la personalización del

aprendizaje a través de tutores inteligentes, sistemas de recomendación y analítica del aprendizaje mejora significativamente el rendimiento académico, la motivación, la autorregulación y la atención a la diversidad (Arias Coronado et al., 2025; Liang et al., 2024; Yang, Xijun y Jiahui, 2023). Por ende, se cree que se cumple la siguiente hipótesis:

H1: El aprendizaje inteligente ejerce efectos positivos en el rendimiento académico de los estudiantes.

2.4. *Inteligencia artificial*

Se define a la inteligencia artificial (IA) como el conjunto de sistemas de capacidades multifacéticas con procesamiento avanzado de datos diseñado para la mejora significativa del aprendizaje. La inteligencia artificial es un optimizador de resultados académicos debido a su eficiencia, precisión y feedback recibido (Shoufan, 2023), y que se relacionan positivamente con el rendimiento académico al fomentar procesos autorregulativos (Jardón Gallegos et al., 2024). Asimismo, Vieriu y Petrea (2025) E7B3} indican que la IA presenta importantes ventajas para los estudiantes como la personalización del aprendizaje, la participación activa y la mejora del acceso equitativo a recursos; logrando una adecuada interacción del alumno y la mejora de la enseñanza (Guacán Tandayamo et al., 2023). De igual manera, Adewale et al. (2024), resalta su alta capacidad transformadora en los procesos de aprendizaje y enseñanza. La resolución de consultas académicas y la mejora en la comprensión conceptual fueron factores importantes para el crecimiento del uso de esta tecnología en estudiantes universitarios (Altikriti y Nemrawi, 2025).

Por otro lado, Wang y Fan (2025) aseguran que sistemas adaptativos de IA incrementan la retención del conocimiento y mejora la carga cognitiva, lo que permite un aprendizaje más eficiente y sostenido en el tiempo. De igual modo, se ha demostrado que la IA es un importante predictor del pensamiento analítico y la resolución de problemas por la mediación del aprendizaje inteligente, especialmente en disciplinas STEM (Alkhatlan y Kalita, 2019). De igual forma, una revisión sistemática menciona que el impacto de la IA en el rendimiento académico es mediado por las interacciones entre los estudiantes y sistemas inteligentes de aprendizaje (García-Martínez et al., 2023). Por ende, se cree que se cumple las siguientes hipótesis:

H2: La inteligencia artificial ejerce efectos positivos en el rendimiento académico de los estudiantes

H3: La inteligencia artificial influye positivamente en el rendimiento académico mediante el aprendizaje inteligente.

2.5. *Redes sociales*

Las redes sociales (RS) se refieren a plataformas digitales promotoras de la interactividad, la retroalimentación inmediata, la participación activa y la gestión eficaz de tareas, lo que contribuye a la comunicación entre alumnos y docentes (Lau, 2017). Otras ventajas ofrecidas por las redes sociales en el ámbito académico son la oferta de espacios interactivos virtuales de educación, la resolución de dudas en tiempo real y el libre acceso a contenidos académicos (Alshantiti et al., 2023). De la misma manera, cumplen un rol fundamental en el desarrollo profesional de los estudiantes universitarios al promocionar competencias, ampliar redes de contacto

y acceder a mejores oportunidades (Akram y Kumar, 2017). Además, actúan de manera colaborativa en la ejecución de determinadas actividades académicas como la comunicación, la facilidad de compartir recursos y el trabajo colaborativo (Gómez-Aguilar, Roses-Campos y Farias-Batlle, 2012).

Por otra parte, Ashraf et al. (2021) indican que el uso de redes sociales en entornos de aprendizaje abierto y colaborativo influyen de manera positiva en el rendimiento académico por factores como la interacción con pares, la utilidad percibida y la facilidad de uso. Asimismo, Badr et al. (2024) relaciona positivamente a las redes sociales y el rendimiento académico, teniendo como mediador al aprendizaje inteligente y resaltando la importancia de la calidad de información en estas plataformas. En conjunto, ambas investigaciones respaldan la hipótesis de que la integración estratégica de redes sociales y tecnologías inteligentes potencian significativamente el rendimiento académico fomentando entornos de aprendizaje más personalizados, interactivos y eficaces. Por ende, se cree que se cumple las siguientes hipótesis:

H4. Las redes sociales ejercen efectos positivos en el rendimiento académico de los estudiantes.

H.5 Las redes sociales influyen positivamente en el rendimiento académico mediante el aprendizaje inteligente.

3. Metodología

3.1. Instrumento de encuesta

El presente estudio incluyó cuatro variables: Inteligencia Artificial que consta de 7 ítems amoldados a lo sugerido por Li (2023) y Shoufan (2023); Redes Sociales que consta de 6 ítems adaptados del estudio de Lau (2017); Aprendizaje inteligente que consta de 4 ítems amoldados al estudio desarrollado por Zang et al. (2022) y como variable dependiente, el Rendimiento Académico que consta de 5 ítems según Whelan et al. (2020). El instrumento se construyó adaptando escalas validadas en estudios anteriores considerando el uso de tecnologías emergentes en el contexto de la educación universitaria. Los constructos examinados se evaluaron mediante la escala Likert de 5 puntos, donde el valor mínimo, 1, representa un desacuerdo absoluto y el valor máximo, 5, representa un acuerdo total.

Los estudios que exploran interacciones complejas requieren de la incorporación de variables de control que fortalezcan la validez de sus resultados. Las variables de control incluidas en este estudio son género, edad y el uso de internet diario para fines académicos. La edad se incluyó debido a que se ha demostrado que estudiantes de diferentes edades presentan niveles distintos de preparación en la educación en línea (Tian y Lu, 2022). Del mismo modo, Goswami y Dutta (2015) nos mencionan que existen diferencias significativas en la experiencia de determinados contenidos educativos digitales basadas en el género del estudiante, por lo que se consideró relevante su inclusión como variable de control. Finalmente, se incluyó el uso diario de internet con fines académicos, ya que el desarrollo de habilidades digitales y su efectividad en un contexto educativo se vinculan con el nivel de exposición tecnológica (Yuan, Yu y Liu, 2025).

3.2. Muestreo y acopio de datos

La investigación es cuantitativa, con un diseño transversal, es decir, la información se

recolectó en un único momento, con el propósito de explicar las relaciones encontradas. La población estudiada fueron estudiantes universitarios de siete universidades de la ciudad de Arequipa en Perú, pertenecientes a las áreas de Ciencias Sociales, Biomédicas e Ingenierías, con un total aproximado a 99950 estudiantes (TUNI.PE, 2025).

Debido a limitaciones de acceso, se empleó un muestreo no aleatorio por conveniencia, una técnica común en estudios exploratorios (Edgar y Manz, 2017). Para determinar el tamaño de la muestra, se aplicó la fórmula correspondiente a poblaciones finitas, buscando un nivel de confianza del 95% y un margen del 5%, lo que indicaba que se necesitaban al menos 384 participantes.

El acopio de datos se realizó durante 5 meses, entre enero y mayo de 2025. A cada participante se le solicitó completar una ficha con datos demográficos: edad, género, nivel de instrucción, uso de Internet para fines académicos y resolución de problemas; y posteriormente se administró el instrumento principal a través de un formulario de Google o también de forma física, dependiendo de la disponibilidad de los estudiantes, recolectándose 542 encuestas en total. Tras aplicar criterios de limpieza de datos se suprimieron casos atípicos y respuestas incompletas, quedando conformada la muestra final con 426 participantes válidos.

Tabla 1: Datos demográficos.

	N=426	%
	Género	
Femenino	215	50.50%
Masculino	211	49.50%
	Edad	
18 a 21	221	51.90%
22 a 25	156	36.60%
26 a 29	40	9.40%
30 a más	9	2.10%
	Uso de Internet para fines académicos diariamente	
Menor a 1h	76	17.80%
Entre 1 a 3h	217	50.90%
Entre 4 a 6h	99	23.20%
Más de 7h	34	8%

3.3. Procedimiento estadístico

El análisis de los datos se realizó en tres fases bien definidas. Primero, los datos fueron limpiados y preparados en Microsoft Excel, eliminando información incompleta y valores incompletos. Segundo, se calcularon estadísticas descriptivas para obtener una descripción detallada de las características sociodemográficas de la muestra. Tercero, se llevó a cabo un Análisis Factorial Exploratorio (AFE) utilizando 426 registros para validar la estructura factorial del cuestionario. El AFE se realizó con el método de máxima verosimilitud y rotación varimax. La adecuación de la muestra para el AFE se confirmó mediante las pruebas de Kaiser-Meyer-Olkin (KMO) y de esfericidad de Bartlett (>0.7). Se descartaron aquellos ítems con cargas factoriales menores a 0.50 y se revisaron los índices de modificación para optimizar el ajuste del modelo.

La fiabilidad se midió a través del alfa de Cronbach y la fiabilidad compuesta (CR), buscando valores superiores a 0.70. La validez discriminante se evaluó utilizando la razón heterorasgo-monorasgo (HTMT) y el criterio de (Fornell y Larcker, 1981).

Además, para asegurar la validez de los resultados, se comprobó la colinealidad entre los constructos utilizando los Factores de Inflación de la Varianza (VIF). Se verificó que todos los valores VIF se mantuvieran por debajo del límite aceptable de 5.

El modelo de investigación se analizó con SmartPLS, un software ampliamente utilizado para la modelización de ecuaciones estructurales basada en mínimos cuadrados parciales (PLS-SEM). Esta técnica es especialmente útil en estudios exploratorios, modelos complejos y muestras que no siguen una distribución normal (Hair Jr et al., 2021). PLS-SEM permitió evaluar de manera rigurosa las relaciones complejas entre las variables dentro del marco teórico propuesto.

3.4. Consideraciones éticas

Las consideraciones éticas se tomaron en cuenta con rigor durante todo el proceso de la investigación, asegurando la participación voluntaria e informando el objeto del estudio y los derechos de los participantes. Además, los datos almacenados se codificaron, se obtuvo la autorización y se garantizó la privacidad con finalidad solamente académica. Las personas encuestadas fueron informadas de su libertad para retirarse en cualquier momento, sin consecuencias negativas.

4. Resultados y discusiones

Para la evaluación de la calidad del modelo de medición en el presente estudio, la garantía de consistencia interna y la determinación de su validez convergente de los constructos latentes, se utilizó el modelo de ecuaciones estructurales de mínimos cuadrados parciales PLS-SEM (Ringle et al., 2018).

Tabla 2: Indicadores de fiabilidad y validez de los constructos.

Variables	Ítem	Cargas	Colinealidad	Alfa de	Fiabilidad	Varianza extraída
		Factoriales		Cronbach	compuesta	media (AVE)
		*> 0.7	*VIF < 3.3	*Confiabilidad > 0.7		*AVE > 0.5
Aprendizaje Inteligente (AIN)	AIN1	0.844	1.948	0.854	0.901	0.695
	AIN2	0.814	1.782			
	AIN3	0.840	2.067			
	AIN4	0.838	2.003			
Inteligencia Artificial (IA)	IA1	0.805	2.287	0.901	0.922	0.629
	IA2	0.845	2.724			
	IA3	0.815	2.310			
	IA4	0.807	2.153			
	IA5	0.753	1.842			
	IA6	0.785	1.966			
	IA7	0.738	1.812			
Redes sociales (RS)	RS1	0.770	1.731	0.859	0.895	0.586
	RS2	0.784	1.853			
	RS3	0.774	1.859			
	RS4	0.754	1.741			
	RS5	0.773	1.874			
	RS6	0.738	1.669			
Rendimiento Académico (RA)	RA1	0.859	2.616	0.895	0.923	0.705
	RA2	0.850	2.507			
	RA3	0.858	2.504			
	RA4	0.829	2.181			
	RA5	0.800	2.030			

Las cargas factoriales estandarizadas permiten el análisis de la contribución individual de los ítems respecto a sus constructos. Según Hair Jr et al. (2021), es recomendable que las cargas factoriales sean mayores a 0.70 para que el indicador explique más del 50% de la varianza compartida con el constructo. Frente a esto, se observa que los constructos estudiados superan de manera significativa el umbral sugerido, lo que garantiza la validez del constructo.

Por su parte, la fiabilidad interna de los constructos fue medida a través del coeficiente de Alfa de Cronbach y la fiabilidad compuesta (CR). Los valores obtenidos superaron el umbral recomendado de 0.70, lo que evidencia una adecuada consistencia interna entre los ítems del mismo constructo (Hair, 2011). Asimismo, los indicadores comparten suficiente varianza común como para representar de forma coherente el constructo subyacente.

Por otro lado, la validez convergente se verificó mediante el Average Variance Extracted (AVE). Los valores obtenidos fueron mayores a 0.5; esto evidencia que cada uno de los constructos explica al menos el 50% de la varianza de sus indicadores asociados, cumpliendo con los criterios establecidos por Fornell y Larcker (1981).

Finalmente, se determinó la colinealidad entre ítems, para ello se calculó el Factor de Inflación de la Varianza (VIF), cuyos valores aceptados deben estar por debajo de 3.3. Según este criterio, los hallazgos evidencian que no existen problemas de multicolinealidad, de esta manera, se garantiza la estabilidad de las estimaciones estructurales (Kock y Lynn, 2012).

El enfoque propuesto por Fornell y Larcker (1981) establece que un constructo debe compartir más varianza con sus propios ítems que con cualquier otro constructo del modelo planteado. Este parámetro es verificado cuando la raíz cuadrada del AVE es superior a todas las correlaciones entre constructos como se denota en la Tabla 3.

Por su parte, el índice HTMT resulta ser una medida más rigurosa y reciente que permite medir la proporción de la media de las correlaciones entre sus diferentes constructos. Existen dos umbrales comunes aceptados para este indicador: el umbral conservador (valores menores a 0.85) y el umbral menos estricto (valores menores a 0.90), ambas medidas evidencian una ausencia de problemas de validez discriminante (Henseler, Ringle y Sarstedt, 2015). En el estudio, los valores obtenidos fueron menores a 0.85, lo que demuestra la inexistencia de problemas de validez de discriminantes, y la ausencia de solapamiento conceptual entre los constructos. Los resultados obtenidos respaldan la fiabilidad y validez del modelo de medición, permitiendo realizar con confianza la evaluación del modelo estructural y la prueba de hipótesis correspondiente.

Tabla 3: Validez de discriminante.

	Aprendizaje Inteligente	Inteligencia Artificial	Redes Sociales	Rendimiento Académico
Aprendizaje Inteligente	0.834	0.730	0.667	0.776
Inteligencia Artificial	0.642	0.793	0.635	0.658
Redes Sociales	0.575	0.561	0.766	0.580
Rendimiento Académico	0.682	0.592	0.513	0.839

Nota. El ratio heterotrait-monotrait (HTMT) sobre el diagonal y el criterio de Fornell-Larcker por debajo de la diagonal. Diagonal principal: en negrita, muestra la raíz cuadrada del AVE.

De esta manera, se procedió a estimar y evaluar el modelo estructural empleando el enfoque de Ecuaciones Estructurales mediante la metodología de Mínimos Cuadrados

Parciales (PLS-SEM), se aplicó un remuestreo de 5000 submuestras (bootstrapping), con un nivel de significancia bilateral del 0.05, obteniendo estimaciones estables con respecto a sus coeficientes de trayectoria, error estándar y valor-p. En la Tabla 4 se evidencian los efectos directos.

Tabla 4: Efectos directos – Bootstrapping.

	Muestra original	Media de la muestra	Desviación estándar	Estadísticos t	P Valores	Resultado
AIN → RA (H1)	0.468	0.463	0.063	7.427	0.000	Respaldado
IA → AIN	0.467	0.467	0.056	8.400	0.000	
IA → RA (H2)	0.217	0.220	0.060	3.628	0.000	
RS → AIN	0.313	0.313	0.047	6.592	0.000	Respaldado
RS → RA (H4)	0.123	0.125	0.051	2.407	0.016	
Uso de internet → RA	0.075	0.076	0.033	2.301	0.021	Respaldado
Edad → RA	-0.004	-0.004	0.034	0.121	0.904	
Género → RA	-0.036	-0.037	0.037	0.959	0.338	

Nota. Se reportan los coeficientes de ruta, medias, desviaciones estándar, valores t, p y resultados de contraste de hipótesis.

Los resultados reflejan que el uso de internet para fines académicos ejerce influencia débil pero positivo en el rendimiento académico (RA) ($\beta=0.075$, $t=2.301$, $p=0.021$), por otra parte, la edad y el género no presentan influencia en el RA con ($\beta=-0.004$, $p=0.904$) y ($\beta=-0.036$, $p=0.338$) respectivamente.

H1: El aprendizaje Inteligente (AIN) ejerce efectos positivos en el rendimiento académico (RA) de los estudiantes ($\beta=0.468$, $t=7.427$, $p=0.000$). El resultado obtenido fue positivo y significativo, validando de esta manera la H1.

De este modo, se pone en evidencia que el aprendizaje inteligente permite a los estudiantes abordar una gran cantidad de temas con mayor eficiencia, logrando la mejora del rendimiento académico en comparación con otros estudiantes (Ling y Chiang, 2022). Asimismo, las tecnologías inteligentes contribuyen a un aprendizaje más personalizado, permitiendo de esta manera el uso de distintas aplicaciones que desarrollan habilidades fundamentales para sus carreras universitarias, fomentando de ese modo la realización profesional de los estudiantes. Esta relación, se encuentra reflejada en estudios que evidenciaron cómo el aprendizaje mediado por tecnologías adaptativas y entornos inteligentes mejora la autonomía del estudiante, logrando una mayor motivación y capacidad de autorregulación (Contrino et al., 2024). Adicionalmente, Alazmi y Alemtairy (2024), destacan que las tecnologías inmersivas y adaptativas fortalecen la comprensión conceptual, el compromiso del estudiante y su rendimiento académico mediante una retroalimentación en tiempo real.

H2. La inteligencia artificial (IA) ejerce efectos positivos en el rendimiento académico (RA) de los estudiantes ($\beta=0.217$, $t=3.628$, $p=0.000$). Aunque la magnitud es menor, se da por aceptada la H2.

La evidencia empírica ratifica que el uso de sistemas de IA logra mejorar el rendimiento académico al optimizar la resolución de tareas, fortaleciendo la comprensión conceptual, logrando una experiencia de aprendizaje activo, autónoma y personalizada. Diversas investigaciones han demostrado que los sistemas de IA generativa, al proporcionar una asistencia personalizada, retroalimentación inmediata y acceso

a la información, permite que los estudiantes puedan abordar temas complejos de forma más efectiva, elevando su rendimiento académico en general. Según Jo (2024), menciona que el uso de ChatGPT mejora la precisión de respuestas, fomentando la autorregulación del aprendizaje y enriqueciendo la experiencia educativa, en especial cuando se usan para preguntas de seguimiento y resolución de problemas académicos.

Por otro lado, Al-Mamary et al. (2024) destaca que herramientas basadas en IA no solo son útiles para la adquisición de conocimientos, fomentando de esta manera la eficiencia cognitiva, facilitando el proceso de análisis, síntesis y aplicación práctica del contenido académico. Siguiendo la misma línea, Ali et al. (2024) subrayan que la IA potencia habilidades claves como el pensamiento crítico, mejor la escritura académica de forma sustancial, lo que facilita la toma de decisiones, dichos factores están asociados de forma directa al logro académico,

H4. Las redes sociales (RS) ejercen efectos positivos en el rendimiento académico (RA) de los estudiantes ($\beta=0.123$, $t=2.407$, $p=0.016$). Por tanto, se respalda la H4.

Los hallazgos indican que la utilización de plataformas sociales tiene un impacto positivo, aunque moderado, en el rendimiento académico, siendo este efecto menor al de la IA en el RA. Esta variación sugiere que, aunque las redes sociales pueden ser beneficiosas para el proceso de aprendizaje, su efectividad depende en gran medida del modo en que se utilicen y del entorno educativo donde se apliquen. Por lo tanto, varios estudios han demostrado que estas plataformas pueden actuar como recursos complementarios para el aprendizaje, facilitando una comunicación tanto en tiempo real como diferida entre los estudiantes, fomentando la colaboración, y aumentando la variedad de recursos y contenidos digitales disponibles (Moqbel y Kock, 2018).

En esa línea, el impacto de las redes sociales no se restringe únicamente a lo técnico, sino que también promueve el fortalecimiento de competencias interpersonales como la colaboración, el razonamiento crítico y la confianza en las capacidades académicas. Este descubrimiento es consistente con investigaciones recientes que resaltan la función de las redes sociales como impulsores de comunidades de aprendizaje dinámicas y comprometidas (Giunchiglia et al., 2018). Sin embargo, también hay investigaciones que evidenciaron efectos contrarios cuando estas plataformas se utilizan con fines no relacionados a lo académico. Kirschner y Karpinski (2010) señalan que el uso intensivo y no regulado de las redes sociales pueden generar distracción, multitarea digital y procrastinación, afectando de forma negativa el desempeño académico.

Tabla 5: Efectos indirectos – Bootstrapping.

	Muestra original	Media de la muestra	Desviación estándar	Estadísticos t	P Valores	Resultado
IA → AIN → RA (H3)	0.218	0.215	0.032	6.744	0.000	Respaldado
RS → AIN → RA (H5)	0.146	0.145	0.032	4.574	0.000	Respaldado

Nota. Se reportan los coeficientes de ruta, medias, desviaciones estándar, valores t, p y resultados de contraste de hipótesis.

Asimismo, para evaluar los efectos indirectos específicos, se empleó el procedimiento Bootstrapping, con la finalidad de determinar los efectos de la mediación.

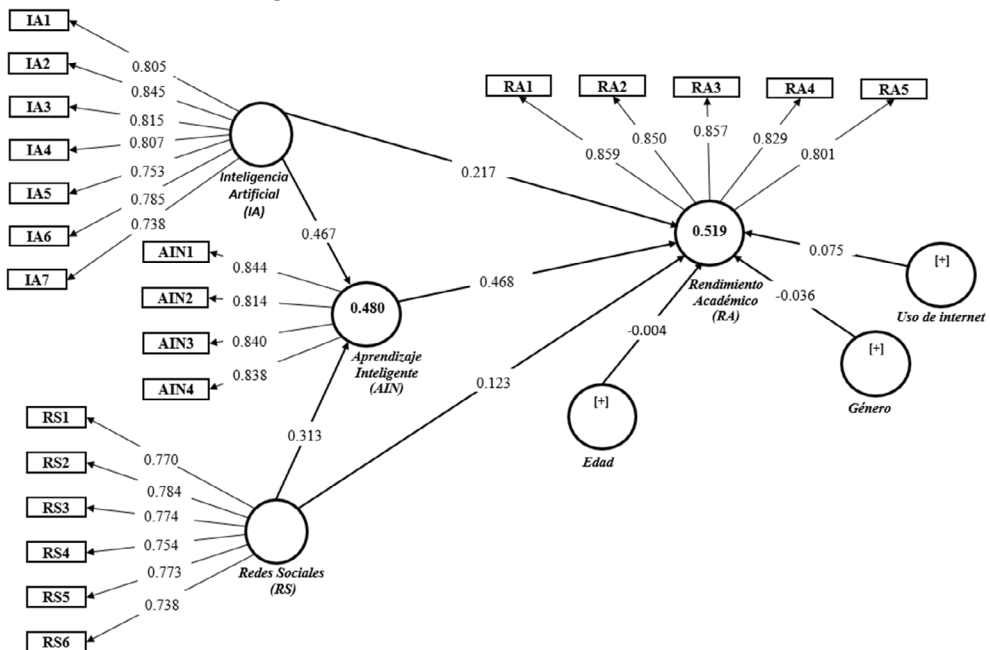
En primer lugar, H3. La inteligencia artificial (IA) influye positivamente sobre el rendimiento académico (RA) mediante el aprendizaje inteligente (AIN) en los estudiantes ($\beta=0.218$, $t=6.744$, $p=0.000$). Este hallazgo evidenció una mediación

significativa, por lo que se da por validada la H3. Esta mediación demuestra que los beneficios de la IA se traducen en mejoras académicas principalmente cuando son canalizados a través de prácticas de aprendizaje activo y autorregulación. Estudios sistemáticos evidencian que las herramientas basadas en IA facilitan personalizar el aprendizaje inteligente y lograr la mejora significativa del rendimiento académico (du Plooy, Casteleijn y Franzsen, 2024; Zawacki-Richter et al., 2019).

En segundo lugar, H5. Las redes sociales (RS) influyen positivamente en el rendimiento académico (RA) mediante el aprendizaje inteligente (AIN) en los estudiantes. ($\beta=0.146$, $t= 4.574$, $p=0.000$). De esta manera se respalda la H5 y se respalda la noción que las redes sociales, si bien tienen un impacto directo limitado sobre el rendimiento académico, pueden potenciar como entornos mediadores que logren facilitar el aprendizaje inteligente.

Por ello, diversas investigaciones han destacado que el uso académico de plataformas como WhatsApp, Facebook o Telegram puede favorecer la colaboración, la interacción entre pares y aprendizaje activo, siendo elementos fundamentales para el logro de competencias claves (Al-Rahmi y Zeki, 2017; Moghavvemi et al., 2018).

Figura 1: Modelo Estructural PLS- SEM.



La figura 1 muestra el modelo estructural el cual fue estimado mediante mínimos cuadrados parciales PLS-SEM, reflejando el impacto de las variables de control en el RA y las relaciones entre los constructos exógenos: Inteligencia Artificial (IA), Redes Sociales (RS) y Aprendizaje Inteligente (AIN), como su influencia sobre su constructo endógeno: Rendimiento Académico (RA). Los resultados obtenidos revelan que el modelo explica en un 51% de la varianza del rendimiento académico ($R^2 = 0.519$), representando un nivel moderado-alto de capacidad explicativa, según los criterios de Chin (2010).

Del mismo modo, el concepto de AIN presenta un coeficiente de determinación $R^2 = 0.480$, lo que avala su función mediadora relevante entre los factores externos

IA y RS y el rendimiento académico. En consecuencia, este descubrimiento indica que las habilidades vinculadas al aprendizaje inteligente, como la autogestión, el análisis crítico y la incorporación de tecnología, no solo impactan de manera directa en el rendimiento académico, sino que también facilitan la influencia positiva de la IA y RS en entornos educativos. Para finalizar, se empleó PLS-predict para evaluar el poder predictivo del modelo al margen de la muestra. La universalización del MECM puede establecerse estimando su precisión en la predicción del valor del resultado de nuevos casos empleando la herramienta PLS-predict (Shmueli et al., 2019). Se usó el modelo de ruta PLS para estimar los valores LM de referencia o benchmark LM a través de regresión lineal para un indicador de constructo endógeno presentado en contraste a un indicador de constructo exógeno preestablecido (Marin-Garcia y Alfalla-Luque, 2019). Posteriormente, siguiendo lo mencionado por Shmueli et al. (2019), se ha comparado el error cuadrático medio (RMSE) con valores del modelo lineal ingenuo (LM). Los resultados evidenciaron que todos los valores predictivos Q2 del PLS-SEM figuran por encima de 0, como se muestra en la tabla 6. Por ende, el PLS-SEM arroja valores RMSE más bajos que los valores de benchmark LM. Según esto, el RMSE logra menores errores de predicción y proporciona una capacidad predictiva positiva (Shmueli et al., 2019).

Tabla 6: Capacidad predictiva del modelo PLS-predict para RA.

	Q ² _predict	PLS_SEM RMSE	LM_RMSE	ΔRMSE
AIN2	0.311	0.725	0.741	- 0.016
AIN4	0.358	0.670	0.684	- 0.014
AIN1	0.373	0.655	0.662	- 0.007
AIN3	0.249	0.730	0.740	- 0.011
RA2	0.300	0.694	0.708	- 0.015
RA5	0.221	0.775	0.798	- 0.023
RA4	0.269	0.705	0.717	- 0.013
RA1	0.288	0.722	0.735	- 0.013
RA3	0.274	0.745	0.762	- 0.018

5. Conclusiones

El presente estudio se basó en la percepción que los estudiantes universitarios tienen sobre el uso de la inteligencia artificial (IA) y las redes sociales (RS) en su vida académica diaria, demostrando que, tanto la IA como la RS se asocian estadísticamente de forma significativa y positiva con el rendimiento académico (RA) de los jóvenes universitarios, cumpliendo el aprendizaje inteligente (AIN) un rol mediador clave en estas relaciones. Sin embargo, de las variables consideradas como de control, solo la cantidad de horas de uso de internet con fines académicos influye en el RA, aunque de forma débil ($\beta=0.075$, $p=0.021$), siendo edad y género irrelevantes ($\beta=-0.004$, $p=0.904$; $\beta=-0.036$, $p=0.338$). Se percibe que el aprendizaje inteligente tiene un impacto positivo en el desempeño escolar, lo cual reafirma la importancia de fomentar habilidades de autogestión, reflexión y manejo de la tecnología para impulsar el buen desempeño de los estudiantes. La Inteligencia artificial aunque con menor intensidad, se asocia de manera directa y positiva con el RA, además, se muestra un impacto indirecto positivo a través del aprendizaje inteligente ($\beta = 0.218$, $p=0.00$), lo que da a entender que su utilidad se multiplica al incorporarse a métodos de estudio activos y bien planeados por estudiantes. Por otro lado, las redes sociales evidenciaron un efecto favorable,

aunque algo menor ($\beta = 0.123$, $p=0.016$), pero su impacto en el desempeño académico incrementa a través del aprendizaje inteligente ($\beta = 0.146$, $p=0.000$).

El modelo estructural pronostica el 51% de la variabilidad en el desempeño académico ($R^2 = 0.519$), indicando un nivel explicativo que oscila entre moderado y elevado. Asimismo, el PLS-predict evidencia que el modelo sugerido tiene un poder predictivo positivo, y que los errores RMSE del PLS-SEM son menores que el LM, lo que demuestra una capacidad de predicción superior al benchmark lineal. Por ello, el modelo evidencia la importancia de fortalecer en los estudiantes las capacidades de aprendizaje adaptativo, así como necesidad de generar espacios que favorezcan el uso estratégico y supervisado de las nuevas tecnologías.

Por ello, se sugiere a las instituciones, ya sean, primarias, secundarias y universitarias fomenten el desarrollo de habilidades que estén vinculadas a estudiar eficientemente, sobre todo el control personal y la reflexión sobre el aprendizaje propio a través de cursos educativos sobre el manejo estratégico de herramientas estratégicas. Las implicancias prácticas que se aportan, consisten en integrar currículos que incluyan la inteligencia artificial y redes sociales que estén preestablecidos intencionalmente con miras a mejorar el rendimiento académico, priorizando la efectividad del aprendizaje independiente. La integración de estas tecnologías puede considerarse como una de las transformaciones más relevantes dentro del proceso histórico de la educación.

5.1. Limitaciones y recomendaciones

La presente investigación tiene ciertas limitaciones que al generalizarlos pueden conllevar a malinterpretar los resultados y las conclusiones. Primero, el enfoque que se ha adoptado es transversal, por lo que se limita declarar los vínculos de causa-efecto de manera específica. En segundo lugar, se levantó información mediante autoevaluaciones, lo cual podría generar sesgos debido a los prejuicios sociales existentes o las percepciones individuales. Se sugiere que futuras investigaciones utilicen grupos de muestras aleatorias, establecer estudios longitudinales y considerar datos verificables del progreso escolar. Asimismo, se aconseja recurrir a evaluaciones imparciales como calificaciones reales, exámenes estandarizados o registros académicos auténticos para la recolección de datos, que permitirán realizar evaluaciones más profundas como análisis econométrico y series de tiempo.

5.2. Agradecimientos

Los autores declaran que este estudio es original. Se ha utilizado una herramienta basada en inteligencia artificial exclusivamente para mejorar la claridad y la gramática. Todo el contenido intelectual, base de datos, análisis y conclusiones son de propiedad exclusiva de los autores.

Referencias

- Adewale, M. D., Azeta, A., Abayomi-Alli, A. y Sambo-Magaji, A. (2024). Impact of artificial intelligence adoption on students' academic performance in open and distance learning: A systematic literature review. *Heliyon*, 10(22), e40025. <https://doi.org/10.1016/j.heliyon.2024.e40025>
- Akram, W. y Kumar, R. (2017). A Study on Positive and Negative Effects of Social Media on Society. *International Journal of Computer Sciences and Engineering*,

5(10), 351-354. <https://doi.org/10.26438/ijcse/v5i10.351354>

- Al-Mamary, Y. H., Alfalah, A. A., Shamsuddin, A. y Abubakar, A. A. (2024). Artificial intelligence powering education: ChatGPT's impact on students' academic performance through the lens of technology-to-performance chain theory. *Journal of Applied Research in Higher Education*, 17(5), 1661-1679. <https://doi.org/10.1108/jarhe-04-2024-0179>
- Al-Rahmi, W. M. y Zeki, A. M. (2017). A model of using social media for collaborative learning to enhance learners' performance on learning. *Journal of King Saud University - Computer and Information Sciences*, 29(4), 526-535. <https://doi.org/10.1016/j.jksuci.2016.09.002>
- Alazmi, H. S. y Alemtairy, G. M. (2024). The effects of immersive virtual reality field trips upon student academic achievement, cognitive load, and multimodal presence in a social studies educational context. *Education and Information Technologies*, 29(16), 22189-22211. <https://doi.org/10.1007/s10639-024-12682-3>
- Ali, D., Fatemi, Y., Boskabadi, E., Nikfar, M., Ugwuoke, J. y Ali, H. (2024). ChatGPT in Teaching and Learning: A Systematic Review. *Education Sciences*, 14(6), 643. <https://doi.org/10.3390/educsci14060643>
- Alkhatlan, A. y Kalita, J. (2019). Intelligent Tutoring Systems: A Comprehensive Historical Survey with Recent Developments. *International Journal of Computer Applications*, 181(43), 1-20. <https://doi.org/10.5120/ijca2019918451>
- Alshantqiti, A., Alharbi, O. A., Ismaeel, D. M. y Abuanq, L. (2023). Social Media Usage and Academic Performance Among Medical Students in Medina, Saudi Arabia. *Advances in Medical Education and Practice*, 14, 1401-1412. <https://doi.org/10.2147/AMEP.S434150>
- Altikriti, S. y Nemrawi, Z. (2025). The Use of ChatGPT as a Learning Tool Among Jordanian Students in Technical Universities: Attitudes and Perceptions. *International Journal of Interactive Mobile Technologies (IJIM)*, 19(05), 144-158. <https://doi.org/10.3991/ijim.v19i05.52049>
- ANDINA. (2025, 24 febrero). *Peru leads the region in workplace AI use*. ANDINA Agencia Peruana de Noticias. <https://bit.ly/4o5AkkL>
- Arias Coronado, J. K., Arias Benalcázar, D. V., Muñoz Herrera, E. J., Campos Ortiz, J. M., Lastra García, E. M. y Guzmán Cabrera, F. E. (2025). Personalización del aprendizaje mediante sistemas de inteligencia artificial adaptativa en entornos virtuales educativos. *Revista Latinoamericana de Calidad Educativa*, 2(2), 69-76. <https://doi.org/10.70625/rlice/159>
- Ashraf, M. A., Khan, M. N., Chohan, S. R., Khan, M., Rafique, W., Farid, M. F., et al. (2021). Social Media Improves Students' Academic Performance: Exploring the Role of Social Media Adoption in the Open Learning Environment among International Medical Students in China. *Healthcare*, 9(10), 1272. <https://doi.org/10.3390/healthcare9101272>
- Badr, A. M. M., Al-Abdi, B. S., Rfeqallah, M., Kasim, R. y Ali, F. A. M. (2024). Information quality and students' academic performance: the mediating roles of perceived

- usefulness, entertainment and social media usage. *Smart Learning Environments*, 11(1), 45. <https://doi.org/10.1186/s40561-024-00329-2>
- Bahn, D. (2001). Social Learning Theory: its application in the context of nurse education. *Nurse Education Today*, 21(2), 110-117. <https://doi.org/10.1054/nedt.2000.0522>
- Bandura, A. (1978). The Self System in Reciprocal Determinism. *American Psychologist*, 33(4), 344-358. <https://doi.org/10.1037/0003-066X.33.4.344>
- Bolaño-García, M. y Duarte-Acosta, N. (2023). Una revisión sistemática del uso de la inteligencia artificial en la educación. *Revista Colombiana de Cirugía*, 39, 51-63. <https://doi.org/10.30944/20117582.2365>
- Chereau, P. y Meschi, P.-X. (2022). Deliberate practice of entrepreneurial learning and self-efficacy: the moderating effect of entrepreneurial parental environment as role modeling. *Journal of Small Business and Enterprise Development*, 29(3), 461-483. <https://doi.org/10.1108/jsbed-07-2021-0277>
- Chin, W. W. (2010). How to Write Up and Report PLS Analyses. En V. Esposito Vinzi, W. W. Chin, J. Henseler, y H. Wang (Eds.), *Handbook of Partial Least Squares: Concepts, Methods and Applications* (pp. 655-690). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-32827-8_29
- Contrino, M. F., Reyes-Millán, M., Vázquez-Villegas, P. y Membrillo-Hernández, J. (2024). Using an adaptive learning tool to improve student performance and satisfaction in online and face-to-face education for a more personalized approach. *Smart Learning Environments*, 11(1), 6. <https://doi.org/10.1186/s40561-024-00292-y>
- Dekker, I., De Jong, E. M., Schippers, M. C., De Bruijn-Smolanders, M., Alexiou, A. y Giesbers, B. (2020). Optimizing Students' Mental Health and Academic Performance: AI-Enhanced Life Crafting. *Frontiers in Psychology*, 11, 1063. <https://doi.org/10.3389/fpsyg.2020.01063>
- du Plooy, E., Casteleijn, D. y Franzsen, D. (2024). Personalized adaptive learning in higher education: A scoping review of key characteristics and impact on academic performance and engagement. *Heliyon*, 10(21), e39630. <https://doi.org/10.1016/j.heliyon.2024.e39630>
- Edgar, T. W. y Manz, D. O. (2017). Exploratory Study. En T. W. Edgar y D. O. Manz (Eds.), *Research Methods for Cyber Security* (pp. 95-130). Syngress. <https://doi.org/10.1016/B978-0-12-805349-2.00004-2>
- Fornell, C. y Larcker, D. F. (1981). Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research*, 18(1), 39-50. <https://doi.org/10.1177/002224378101800104>
- García-Martínez, I., Fernández-Batanero, J. M., Fernández-Cerero, J. y León, S. P. (2023). Analysing the Impact of Artificial Intelligence and Computational Sciences on Student Performance: Systematic Review and Meta-analysis. *Journal of New Approaches in Educational Research*, 12(1), 171-197. <https://doi.org/10.7821/naer.2023.1.1240>
- García-Peñalvo, F. J., Casado-Lumbreras, C., Colomo-Palacios, R. y Yadav, A. (2020).

- Smart Learning. *Applied Sciences*, 10(19), 6964. <https://doi.org/10.3390/app10196964>
- Giunchiglia, F., Zeni, M., Gobbi, E., Bignotti, E. y Bison, I. (2018). Mobile social media usage and academic performance. *Computers in Human Behavior*, 82, 177-185. <https://doi.org/10.1016/j.chb.2017.12.041>
- Gómez-Aguilar, M., Roses-Campos, S. y Farias-Batlle, P. (2012). The academic use of social networks among university students [El uso académico de las redes sociales en universitarios]. *Comunicar*, 38, 131-138. <https://doi.org/10.3916/C38-2012-03-04>
- Goswami, A. y Dutta, S. (2015). Gender Differences in Technology Usage—A Literature Review. *Open Journal of Business and Management*, 4(1), 51-59. <https://doi.org/10.4236/ojbm.2016.41006>
- Guacán Tandayamo, R. C., Miguez Haro, R. E., Lozada Lozada, R. F., Jácome Cobos, D. I. y Cruz Gaibor, W. A. (2023). La Inteligencia Artificial Utilizada como un Recurso para el Aprendizaje. *Ciencia Latina Revista Científica Multidisciplinar*, 7(4), 8263-8277. https://doi.org/10.37811/cl_rcm.v7i4.7561
- Hailu, M., Abie, A., Mehari, M. G., Dagnaw, T. E., Worku, N. K., Esubalew, D., et al. (2024). Magnitude of academic performance and its associated factors among health science students at Eastern Ethiopia University's 2022. *BMC Medical Education*, 24(1), 1288. <https://doi.org/10.1186/s12909-024-06296-z>
- Hair, J. F. (2011). Multivariate Data Analysis: An Overview. En M. Lovric (Ed.), *International Encyclopedia of Statistical Science* (pp. 904-907). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-04898-2_395
- Hair Jr, J. F., Hult, G. T. M., Ringle, C. M., Sarstedt, M., Danks, N. P. y Ray, S. (2021). *Partial Least Squares Structural Equation Modeling (PLS-SEM) Using R: A Workbook*. Springer. <https://doi.org/10.1007/978-3-030-80519-7>
- Henseler, J., Ringle, C. M. y Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43(1), 115-135. <https://doi.org/10.1007/s11747-014-0403-8>
- IBM Latinoamérica. (2024, 20 de marzo). *Empresas de Latinoamérica aceleraron el uso de inteligencia artificial en 67%* [Comunicado de prensa]. IBM Newsroom Latinoamérica. <https://bit.ly/46qTSIr>
- Jardón Gallegos, M. d. C., Granizo Malusin, J. H., Yaselga Auz, W. F. y Cocha Telenchana, M. G. (2024). Impacto de los asistentes virtuales de inteligencia artificial en el rendimiento académico de estudiantes universitarios. *Revista Social Fronteriza*, 4(4), e44338. [https://doi.org/10.59814/resofro.2024.4\(4\)338](https://doi.org/10.59814/resofro.2024.4(4)338)
- Jimbo-Santana, P., Lanzarini, L. C., Jimbo-Santana, M. y Morales-Morales, M. (2023). Inteligencia artificial para analizar el rendimiento académico en instituciones de educación superior. Una revisión sistemática de la literatura. *Cátedra*, 6(2), 30-50. <https://doi.org/10.29166/catedra.v6i2.4408>

- Jo, H. (2024). From concerns to benefits: a comprehensive study of ChatGPT usage in education. *International Journal of Educational Technology in Higher Education*, 21(1), 35. <https://doi.org/10.1186/s41239-024-00471-4>
- Kirschner, P. A. y Karpinski, A. C. (2010). Facebook® and academic performance. *Computers in Human Behavior*, 26(6), 1237-1245. <https://doi.org/10.1016/j.chb.2010.03.024>
- Kock, N. y Lynn, G. S. (2012). Lateral Collinearity and Misleading Results in Variance-Based SEM: An Illustration and Recommendations. *Journal of the Association for Information Systems*, 13(7), 2. <https://doi.org/10.17705/1jais.00302>
- Lau, W. W. F. (2017). Effects of social media usage and social media multitasking on the academic performance of university students. *Computers in Human Behavior*, 68, 286-291. <https://doi.org/10.1016/j.chb.2016.11.043>
- Li, K. (2023). Determinants of College Students' Actual Use of AI-Based Systems: An Extension of the Technology Acceptance Model. *Sustainability*, 15(6), 5221. <https://doi.org/10.3390/su15065221>
- Liang, H., Wenmin, X., Wenxi, Z., Lihua, Z. y Yueting, H. U. (2024). Impact of Artificial Intelligence, Smart Learning and Belief About Future on Academic Performance & Moderating Effect of Desire for Knowledge. *Profesional de la información*, 33(4), e330418. <https://doi.org/10.3145/epi.2024.ene.0418>
- Ling, H.-C. y Chiang, H.-S. (2022). Learning Performance in Adaptive Learning Systems: A Case Study of Web Programming Learning Recommendations. *Frontiers in Psychology*, 13, 770637. <https://doi.org/10.3389/fpsyg.2022.770637>
- Marin-Garcia, J. y Alfalla-Luque, R. (2019). Key issues on Partial Least Squares (PLS) in operations management research: A guide to submissions. *Journal of Industrial Engineering and Management*, 12(2), 219-240. <https://doi.org/10.3926/jiem.2944>
- Moghavvemi, S., Sulaiman, A., Jaafar, N. I. y Kasem, N. (2018). Social media as a complementary learning tool for teaching and learning: The case of youtube. *The International Journal of Management Education*, 16(1), 37-42. <https://doi.org/10.1016/j.ijme.2017.12.001>
- Moqbel, M. y Kock, N. (2018). Unveiling the dark side of social networking sites: Personal and work-related consequences of social networking site addiction. *Information & Management*, 55(1), 109-119. <https://doi.org/10.1016/j.im.2017.05.001>
- Nadeem, M. (2024). Distributed leadership in educational contexts: A catalyst for school improvement. *Social Sciences & Humanities Open*, 9, 100835. <https://doi.org/10.1016/j.ssaho.2024.100835>
- Naser, S. A., Zaqout, I., Ghosh, M. A., Atallah, R. y Alajrami, E. (2015). Predicting Student Performance Using Artificial Neural Network: in the Faculty of Engineering and Information Technology. *International Journal of Hybrid Information Technology*, 8(2), 221-228. <https://doi.org/10.14257/ijhit.2015.8.2.20>

- Navarro, R. E. (2016). El rendimiento académico: concepto, investigación y desarrollo. *REICE. Revista Iberoamericana sobre Calidad, Eficacia y Cambio en Educación*, 1(2), 1-15. <https://doi.org/10.15366/reice2003.1.2.007>
- Pang, H. y Yang, T. (2024). Network Structure Matters: Unpacking Associations Among Informational WeChat Use, Network Heterogeneity, Network Capital, and Civic Involvement. *Sage Open*, 14(2), 21582440241253051. <https://doi.org/10.1177/21582440241253051>
- Pang, H. y Zhang, K. (2024). Determining influence of service quality on user identification, belongingness, and satisfaction on mobile social media: Insight from emotional attachment perspective. *Journal of Retailing and Consumer Services*, 77, 103688. <https://doi.org/10.1016/j.jretconser.2023.103688>
- Popescu, E. (2014). Providing collaborative learning support with social media in an integrated environment. *World Wide Web*, 17(2), 199-212. <https://doi.org/10.1007/s11280-012-0172-6>
- Ray, P. P. (2023). ChatGPT: A comprehensive review on background, applications, key challenges, bias, ethics, limitations and future scope. *Internet of Things and Cyber-Physical Systems*, 3, 121-154. <https://doi.org/10.1016/j.iotcps.2023.04.003>
- Ringle, C. M., Sarstedt, M., Mitchell, R. y Gudergan, S. P. (2018). Partial least squares structural equation modeling in HRM research. *The International Journal of Human Resource Management*, 31(12), 1617-1643. <https://doi.org/10.1080/09585192.2017.1416655>
- Rosales-Ronquillo, C. A. y Hernández-Jáquez, L. F. (2020). Academic Self-Efficacy and Its Relationship With Academic Performance in Nutrition Students. *Revista Electrónica Educare*, 24(3), 1-17. <https://doi.org/10.15359/ree.24-3.7>
- Sánchez-Reina, R., Theophilou, E., Ognibene, D. y Hernández-Leo, D. (2023). "Shall We Rely on Bots?" Students' Adherence to the Integration of ChatGPT in the Classroom. En *HELMeTO 2023 - Book of Abstracts* (pp. 128-130). STUDIUM s.r.l. a socio unico. <https://hdl.handle.net/10281/472244>
- Shafiq, M. y Parveen, K. (2023). Social media usage: Analyzing its effect on academic performance and engagement of higher education students. *International Journal of Educational Development*, 98, 102738. <https://doi.org/10.1016/j.ijedudev.2023.102738>
- Shahzad, M. F., Xu, S., Lim, W. M., Yang, X. y Khan, Q. R. (2024). Artificial intelligence and social media on academic performance and mental well-being: Student perceptions of positive impact in the age of smart learning. *Heliyon*, 10(8), e29523. <https://doi.org/10.1016/j.heliyon.2024.e29523>
- Shmueli, G., Sarstedt, M., Hair, J. F., Cheah, J.-H., Ting, H., Vaithilingam, S., et al. (2019). Predictive model assessment in PLS-SEM: guidelines for using PLSpredict. *European Journal of Marketing*, 53(11), 2322-2347. <https://doi.org/10.1108/ejrm-02-2019-0189>
- Shoufan, A. (2023). Exploring Students' Perceptions of ChatGPT: Thematic Analysis and Follow-Up Survey. *IEEE Access*, 11, 38805-38818. <https://doi.org/10.1109/ACCESS.2023.3268224>

- Sisalima, M. C. S., Masabanda, D. D. R., Quizhpe, M. J. L. y Reyes, Y. E. M. (2024). Impacto de la inteligencia artificial en la adaptación de los estilos de aprendizaje y el rendimiento académico: un análisis bibliométrico. *Reincisol*, 3(6), 4989-5014. [https://doi.org/10.59282/reincisol.v3\(6\)4989-5014](https://doi.org/10.59282/reincisol.v3(6)4989-5014)
- Smart, S. y Montori, V. M. (2025, 23 abril). *Peru's AI Regulatory Boom: Quantity Without Depth?* Harvard Kennedy School. <https://bit.ly/3GWAKJG>
- Tian, M. y Lu, G. (2022). Online learning satisfaction and its associated factors among international students in China. *Frontiers in Psychology*, 13, 916449. <https://doi.org/10.3389/fpsyg.2022.916449>
- TUNI.PE. (2025). *Informe basado en datos del SUNEDU*. <https://www.tuni.pe/comunidad/estudiantes>
- Vieriu, A. M. y Petrea, G. (2025). The Impact of Artificial Intelligence (AI) on Students' Academic Development. *Education Sciences*, 15(3), 343. <https://doi.org/10.3390/educsci15030343>
- Wang, J. y Fan, W. (2025). The effect of ChatGPT on students' learning performance, learning perception, and higher-order thinking: insights from a meta-analysis. *Humanities and Social Sciences Communications*, 12(1), 621. <https://doi.org/10.1057/s41599-025-04787-y>
- Whelan, E., Islam, A. K. M. N. y Brooks, S. (2020). Applying the SOBC paradigm to explain how social media overload affects academic performance. *Computers & Education*, 143, 103692. <https://doi.org/10.1016/j.compedu.2019.103692>
- Yang, W., Xijun, W. y Jiahui, D. (2023). Impact of smart classrooms in higher education on academic performance: a meta-analysis. *Regional Journal of Information and Knowledge Management*, 8(2), 135-148. <https://www.ajol.info/index.php/rjkm/article/view/263066>
- Yuan, N., Yu, Q. y Liu, W. (2025). The impact of digital literacy on learning outcomes among college students: the mediating effect of digital atmosphere, self-efficacy for digital technology and digital learning. *Frontiers in Education*, 10, 1641687. <https://doi.org/10.3389/feduc.2025.1641687>
- Zang, J., Kim, Y. y Dong, J. (2022). New evidence on technological acceptance model in preschool education: Linking project-based learning (PBL), mental health, and semi-immersive virtual reality with learning performance. *Frontiers in Public Health*, 10, 964320. <https://doi.org/10.3389/fpubh.2022.964320>
- Zawacki-Richter, O., Marín, V. I., Bond, M. y Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*, 16(1), 39. <https://doi.org/10.1186/s41239-019-0171-0>