



KAIRÓS, Revista de Ciencias Económicas, Jurídicas y Administrativas

ISSN: 2631-2743

ISSN-L: 2631-2743

kairos@unach.edu.ec

Universidad Nacional de Chimborazo
Ecuador

Romero Calle, Génesis P.; Tivillin-Gutama, Dilia M.; Bonisoli, Lorenzo
LA INTELIGENCIA ARTIFICIAL Y SU INFLUENCIA EN EL COMPORTAMIENTO DE LOS ESTUDIANTES

KAIRÓS, Revista de Ciencias Económicas, Jurídicas y
Administrativas, vol. 8, núm. 14, 2025, Enero-Junio, pp. 67-87
Universidad Nacional de Chimborazo
Ecuador

DOI: <https://doi.org/10.37135/kai.03.14.04>

Disponible en: <https://www.redalyc.org/articulo.oa?id=721980753004>

- Cómo citar el artículo
- Número completo
- Más información del artículo
- Página de la revista en redalyc.org

redalyc.org

Sistema de Información Científica Redalyc
Red de revistas científicas de Acceso Abierto diamante
Infraestructura abierta no comercial propiedad de la academia

Génesis P. Romero-Calle

gromero10@utmachala.edu.ec

Universidad Técnica de Machala

(Machala - Ecuador)

ORCID: 0009-0008-7384-5449

Dilia M. Tivillin-Gutama

dtivillin1@utmachala.edu.ec

Universidad Técnica de Machala

(Machala - Ecuador)

ORCID: 0009-0005-5071-433X

Lorenzo Bonisoli

lbonisoli@utmachala.edu.ec

Facultad de Ciencias Empresariales

Universidad Técnica de Machala

(Machala - Ecuador)

ORCID: 0000-0003-3336-5658

Recibido: 27/08/2024

Aceptado: 27/12/2024

LA INTELIGENCIA ARTIFICIAL Y SU INFLUENCIA EN EL COMPORTAMIENTO DE LOS ESTUDIANTES

ARTIFICIAL INTELLIGENCE AND ITS INFLUENCE ON STUDENT BEHAVIOR

DOI:

<https://doi.org/10.37135/kai.03.14.04>

Resumen

El propósito del presente estudio es analizar la influencia de la motivación intrínseca, extrínseca, habilidades y normas subjetivas en la adopción de inteligencia artificial (IA) por parte de estudiantes ecuatorianos. Se utilizó una metodología cuantitativa para medir la intención y el comportamiento de uso de la IA, basada en un modelo de Ecuaciones Estructurales con Mínimos Cuadrados Parciales (SEM-PLS). La muestra consistió en 223 estudiantes encuestados. Los resultados revelan que la motivación extrínseca, intrínseca, intención de uso y comportamiento tienen un impacto significativo en los estudiantes, mientras que las habilidades y normas subjetivas no influyen directamente en ellos.

Palabras clave: aptitud, conducta, autodisciplina, aprendizaje, actitud.

Abstract

The purpose of the present study is to analyze the influence of intrinsic and extrinsic motivation, skills, and subjective norms on the adoption of artificial intelligence (AI) by Ecuadorian students. A quantitative methodology was used to measure the intention and behavior of using AI, based on a Structural Equation Model with Partial Least Squares (SEM-PLS). The sample consisted of 223 surveyed students. The results reveal that extrinsic and intrinsic motivation, intention to use, and behavior have a significant impact on students, while skills and subjective norms do not directly influence them.

Keywords: aptitude, behavior, self-discipline, learning, attitude.

LA INTELIGENCIA ARTIFICIAL Y SU INFLUENCIA EN EL COMPORTAMIENTO DE LOS ESTUDIANTES

ARTIFICIAL INTELLIGENCE AND ITS INFLUENCE ON STUDENT BEHAVIOR

DOI:

<https://doi.org/10.37135/kai.03.14.04>

Introducción

La tecnología ha transformado profundamente diversos aspectos de la vida cotidiana y profesional en las últimas décadas, desempeñando un papel esencial en la innovación y la eficiencia (Belanger & Crossler, 2019). La rápida evolución de las tecnologías emergentes, como la inteligencia artificial (IA), está cambiando la forma en que interactuamos con el mundo, ofreciendo nuevas oportunidades (Rochina Chileno *et al.*, 2024).

En el ámbito educativo, la inteligencia artificial ha demostrado un impacto significativo al permitir la personalización de aprendizaje y la optimización de enseñanza. Por ejemplo, la IA puede facilitar un aprendizaje más efectivo mediante sistemas adaptativos que responden a las necesidades individuales de los estudiantes (Dwivedi *et al.*, 2019). Sin embargo, en Ecuador, la integración de la IA en la educación enfrenta desafíos relacionados con la falta de investigaciones que exploren cómo factores clave, influyen en el comportamiento de los estudiantes al adoptar esta tecnología.

Uno de los problemas principales es comprender qué factores motivan a los estudiantes ecuatorianos a adoptar la IA como herramienta en sus actividades académicas. Este fenómeno plantea interrogantes sobre variables como la motivación intrínseca (interés personal y satisfacción interna), la motivación extrínseca (recompensas externas y reconocimiento), las habilidades tecnológicas (competencia para interactuar con herramientas avanzadas) y las normas subjetivas (presión social o expectativas percibidas) (Zaccone y Pedrini, 2019).

Aunque la IA ha sido objeto de múltiples estudios en el ámbito educativo, la mayoría se enfoca en contextos internacionales o en aspectos generales, como la intención de uso y el comportamiento de adopción de tecnología. Existe, sin embargo, una carencia de investigaciones que analicen cómo estas cuatro variables afectan específicamente la adopción de la IA en el contexto ecuatoriano, un país que enfrenta limitaciones y oportunidades únicas (Zarouali *et al.*, 2018). Este vacío en el conocimiento limita la capacidad de implementar estrategias efectivas que promuevan el uso adecuado de la IA en el ámbito educativo (Montalván-Vélez *et al.*, 2024).

Por esta razón, este estudio tiene como objetivo analizar cómo la motivación intrínseca, la motivación extrínseca, las habilidades y las normas subjetivas influyen en la adopción de la inteligencia artificial entre los estudiantes ecuatorianos. Este análisis busca proporcionar un entendimiento más detallado de los factores que determinan la disposición de los estudiantes a integrar herramientas de IA en su proceso de aprendizaje y rendimiento académico (Xu *et al.*, 2023).

Este estudio podría ser relevante para académicos especializados en tecnología educativa, así como para instituciones educativas, al proporcionar una comprensión detallada de por qué los

estudiantes en Ecuador se relacionan con el uso de la tecnología en sus tareas académicas. Además, los educadores interesados en promover el aprendizaje efectivo podrían beneficiarse al utilizar los hallazgos de este estudio para fomentar el uso consciente y efectivo de la inteligencia artificial en el entorno educativo.

Materiales y métodos

Comportamiento de uso (CU) e Intención de uso (IU)

El comportamiento de uso se define como la percepción subjetiva de una persona sobre la probabilidad de llevar a cabo una acción particular, influyendo en sus decisiones de consumo de un producto o adquisición de alguna tecnología específica (Christino *et al.*, 2021). La intención de uso, por su parte, es un factor central que motiva a un individuo a realizar una conducta específica (Perri *et al.*, 2020). En estudios recientes, como el de Carranza *et al.* (2021) basado en la Teoría de la Acción Razonada (TRA), se ha investigado cómo la intención de uso afecta la decisión de los consumidores de adoptar productos o tecnologías, resalta la importancia de entender la intención de uso, ya que puede determinar la adopción de tecnologías emergentes como la inteligencia artificial en la educación.

Además, Tilibaşa *et al.* (2023) afirman que la integración de la inteligencia artificial puede facilitar el desarrollo de habilidades de pensamiento crítico entre los estudiantes y aumentar su motivación y compromiso con el aprendizaje. En particular, se considera que la facilidad de acceso a la información, gracias a la proliferación de recursos digitales y plataformas en línea, también es un factor clave que incrementa la intención de uso de tecnologías educativas (Singh *et al.*, 2020), ofreciendo a estudiantes y educadores acceso a materiales educativos, textos y documentos, vídeos y simulaciones interactivas. Por ende, la intención de uso y el comportamiento de uso deben considerarse como factores estrechamente relacionados, trabajando juntos para realizar acciones específicas. Por lo tanto, se plantea la siguiente hipótesis:

H1: La intención de uso influye positivamente en el comportamiento de uso.

Motivación intrínseca (MI)

La Teoría de la Autodeterminación (SDT), se centra en la motivación y el crecimiento personal. Esta teoría sostiene que para que las personas se comprometan de manera efectiva con una tarea, deben satisfacer tres necesidades psicológicas básicas: autonomía, competencia y relación. La satisfacción de estas necesidades facilita una mayor motivación intrínseca y una mayor integración del comportamiento en el sentido de identidad personal y valores (Zacccone & Pedrini, 2019).

La motivación intrínseca se refiere a la realización de una tarea sin la necesidad de incentivos externos, siendo el propio proceso de ejecución de la actividad la recompensa principal, como la sensación de placer experimental durante el proceso (Wang *et al.*, 2022). La motivación intrínseca juega un papel significativo en las intenciones de adoptar una innovación tecnológica. Aquellos que experimentan una motivación interna hacia la utilización de la tecnología están más propensos a encontrar satisfacción en su uso continuo para lograr tareas específicas relacionadas con su aplicación.

Para estos usuarios, los obstáculos asociados con la nueva tecnología suelen ser menores, ya que perciben el uso de la inteligencia artificial como algo más sencillo y disfrutan del proceso de emplearla (Chaurasia *et al.*, 2019). Se podría argumentar que, en el ámbito de la innovación tecnológica, el uso continuo para lograr tareas específicas relacionadas con su aplicación, como tareas de estudio, puede afectar a la adopción de los estudiantes a adoptar y utilizarla de manera continua en el tiempo. En este sentido, podría existir una relación positiva entre la motivación intrínseca de los estudiantes hacia la adopción de una innovación tecnológica y su voluntad de mantener un uso constante de la misma (Wu *et al.*, 2022).

Por consiguiente, la motivación intrínseca juega un papel crucial en fomentar un compromiso continuo con la inteligencia artificial entre los estudiantes, lo que conlleva beneficios tangibles, como una mayor eficiencia en la realización de tareas académicas y un aprovechamiento más completo de las capacidades de la inteligencia artificial en cuestión (Amani *et al.*, 2022). Por lo tanto, se formula la siguiente hipótesis:

H2: La motivación intrínseca afectará positivamente la intención de uso al utilizar la IA.

Aunque la motivación intrínseca es crucial para la participación inicial y el compromiso con la tarea, el comportamiento de uso puede depender más de factores extrínsecos y contextuales, como recompensas y reconocimientos (Malek *et al.*, 2020). Esto nos lleva a plantear la siguiente hipótesis:

H3: Motivación intrínseca no tiene un efecto significativo en comportamiento de uso.

Motivación extrínseca (ME)

La motivación extrínseca en el contexto del aprendizaje se refiere a la tendencia de realizar una actividad educativa impulsada por la búsqueda de recompensas externas o la evitación de consecuencias negativas, en lugar de encontrar satisfacción intrínseca en el proceso de aprendizaje en sí mismo. Este tipo de motivación puede estar vinculado a la percepción de utilidad tangible o beneficios prácticos que se obtienen al completar la tarea educativa (Urhahne & Wijnia, 2023).

En el ámbito estudiantil y la integración de la inteligencia artificial, la motivación extrínseca se posiciona como un elemento igualmente relevante que la motivación intrínseca para influir en el comportamiento. Esta motivación externa, proveniente de la comunicación interpersonal y recompensas, ejerce un fuerte impacto en las conductas de los estudiantes. Según estudios recientes, la motivación extrínseca proporcionada por señales de estímulo-respuesta puede influir mucho en la intención de uso más que los motivadores intrínsecos (Seo *et al.*, 2021).

Con respecto a la tecnología inteligente, como la inteligencia artificial, tanto las razones externas como las internas son importantes para motivar a los usuarios. Las razones externas pueden ser cosas como recompensas o influencias de otras personas, mientras que las internas vienen de nuestro propio interés y satisfacción personal (Yin *et al.*, 2021).

En un entorno educativo mediado por la tecnología, la presencia de motivadores extrínsecos podría tener un efecto significativo en la intención de los estudiantes de usar la inteligencia artificial. En el ámbito de la educación y la tecnología, se plantea que las recompensas externas pueden aumentar el deseo de utilizar la tecnología, como la obtención de buenos resultados en las tareas. Sin embargo, un exceso de estas recompensas podría conducir a una pérdida del verdadero disfrute del proceso de aprendizaje (Kusumawati *et al.*, 2023).

Por lo tanto, se plantea la idea de que, si bien las recompensas externas pueden motivar a los estudiantes a utilizar más la inteligencia artificial para el estudio, también es crucial mantener el disfrute del proceso del aprendizaje. Así se plantea la siguiente hipótesis:

H4: La motivación extrínseca influye positivamente en la intención de los estudiantes de utilizar la inteligencia artificial para fines académicos.

La motivación extrínseca también puede influir directamente en el uso de la inteligencia artificial por parte de los estudiantes. Las recompensas y otros incentivos pueden no solo aumentar la intención de uso sino también, facilita la traducción de esta intención en comportamiento real (Shneor & Munim, 2019). Los factores de la motivación extrínseca son efectivos positivos en promover el uso de la inteligencia artificial. Por lo tanto, se desarrolla la siguiente hipótesis.

H5: La motivación extrínseca tiene un efecto positivo y significativo en la intención de comportamiento de los estudiantes al utilizar la inteligencia artificial para sus estudios.

Habilidad (HA)

La habilidad se define como la capacidad de una persona para llevar a cabo acciones específicas. Aunque una persona pueda estar muy motivada, es poco probable que realice una tarea específica si no cuenta con las habilidades necesarias (Strzelecki, 2023). Dentro del contexto

de la inteligencia artificial, se ha observado que la habilidad percibida para usarla no siempre se correlaciona con la intención de utilizarla.

A pesar de que los estudiantes pueden sentirse competentes o seguros de sus habilidades relacionadas con la Inteligencia artificial, esto no necesariamente se traduce en una disposición activa para utilizarla de manera efectiva en sus actividades académicas. Los estudios sugieren que los estudiantes pueden creer que poseen las habilidades necesarias para interactuar con la inteligencia artificial, pero esto no garantiza que estén dispuestos o motivados a utilizarla de manera efectiva.

Esta discrepancia indica que la percepción de habilidad podría no influir directamente en la intención de uso de la inteligencia artificial en sus estudios y rendimiento académico. Factores adicionales podrían mediar en la relación entre la habilidad percibida y la intención de uso por el cual se basó en la revisión de la literatura, se plantea la siguiente hipótesis:

H6: La habilidad para utilizar la inteligencia artificial no influye positivamente con la intención de los estudiantes de emplearla como herramienta en su proceso de aprendizaje y rendimiento académico.

Las habilidades son esenciales para la capacidad de los estudiantes de utilizar la inteligencia artificial, pero no necesariamente se traduce directamente en el comportamiento de uso. Aunque las habilidades son un requisito para el uso efectivo de la IA, el comportamiento de uso puede estar influenciado por otros factores como la motivación intrínseca. Tener habilidades no garantiza necesariamente el uso de la IA (Chan & Lee, 2023).

H7: La habilidad no influye directamente en el comportamiento de uso.

Normas subjetivas (NS)

Las normas subjetivas se refieren a la percepción que tienen los individuos sobre las expectativas sociales y la presión de sus pares para realizar o abstenerse de realizar un comportamiento específico. Este constructo es un componente clave en la Teoría del Comportamiento Planificado (Ajzen, 2020), que sugiere que las decisiones individuales están significativamente influenciadas por la aprobación o desaprobación percibida de personas importantes para ellos, como familiares, amigos y colegas (Leong *et al.*, 2023).

En el ámbito de la tecnología, y más específicamente de la inteligencia artificial, las normas subjetivas han sido utilizadas para entender cómo las percepciones y presiones sociales influyen en la adopción y uso de nuevas tecnologías. Por ejemplo, estudios recientes han demostrado que las normas subjetivas influyen en la aceptación de chatbots y asistentes virtuales, y en cómo los

individuos perciben la utilidad y facilidad de uso de estas tecnologías (Brachten *et al.*, 2021). En el contexto de la educación, se ha observado que la presión de pares y las expectativas de los profesores pueden motivar a los estudiantes a utilizar tecnologías avanzadas como la IA para mejorar su aprendizaje y desempeño académico (Zarouali *et al.*, 2018).

Las normas subjetivas podrían tener una influencia significativa en la intención de uso de la inteligencia artificial en estudiantes. Las percepciones de aprobación o desaprobación social podrían afectar la disposición de los estudiantes para utilizar la IA en sus actividades académicas. Esta propuesta se basa en estudios que sugieren que las normas subjetivas pueden jugar un rol importante en la formación de intenciones de uso hacia nuevas tecnologías, al influir en cómo los individuos valoran la adopción de estas herramientas en contextos específicos (Nguyen & Ho, 2022). Por lo consiguiente se desarrolla la hipótesis:


H8: Las normas subjetivas tienen una relación significativa con la intención de uso de inteligencia artificial en estudiantes.

De manera similar, se considera que las normas subjetivas podrían impactar el comportamiento real de uso de la inteligencia artificial entre los estudiantes. La presión social y las expectativas de los compañeros y profesores podrían influir en cómo y con qué frecuencia los estudiantes utilizan tecnologías avanzadas como la IA en su entorno académico. Esta hipótesis se fundamenta en investigaciones que han observado que las expectativas sociales pueden determinar el grado de uso de nuevas tecnologías (Zarouali *et al.*, 2018). Por lo tanto, se genera la siguiente hipótesis:

H9: Las normas subjetivas tienen una relación significativa con el comportamiento de uso de inteligencia artificial en estudiantes.

En la figura 1 se presenta el modelo teórico.

Figura 1. Modelo Teórico.



Fuente: elaboración propia.

Metodología

El instrumento de investigación consistió en un cuestionario compuesto por 3 preguntas descriptivas (género, edad, ingresos familiares) y 24 ítems que miden variables clave como el comportamiento de uso, la intención de uso, la motivación extrínseca e intrínseca, las habilidades y las normas subjetivas (Apéndice 1). Cada ítem fue evaluado mediante una escala de Likert de 7 puntos. Antes de ser enviado a los encuestados, los ítems fueron validados mediante técnicas cualitativas, basadas en entrevistas personales a un panel de expertos en el área de estudio. Esta validación permitió evitar problemas relacionados con la comprensión de los indicadores, la traducción al español, y el diferente contexto cultural de aplicación.

La muestra fue seleccionada utilizando una técnica no probabilística de conveniencia, dirigida a estudiantes de educación superior. En la encuesta participaron 268 personas, pero tras el análisis de las respuestas no pertinentes, se cancelaron 45 respuestas, resultando en 223 respuestas válidas para el estudio.

La encuesta fue distribuida a través de chat, utilizando contactos personales mediante la técnica de bola de nieve. Para analizar los resultados obtenidos, se empleó la técnica del Modelo de Ecuaciones Estructurales basado en la varianza (SEM-PLS) con enfoque en los mínimos cuadrados parciales, y se utilizó el programa SmartPLS (Ringle, C. M., Wende, S., y Becker, J.-M. 2024. “SmartPLS 4.” Bönningstedt: SmartPLS, <https://www.smartpls.com>) para la elaboración de los resultados.

Tabla 1. Análisis descriptivo

Genero	Frecuencia	Porcentaje
Masculino	108	40.3%
Femenino	160	59.7%
Total	268	100%
Edad	Frecuencia	Porcentaje
17-20 años	74	27.6%
21-25 años	126	47.0%
26-30 años	29	10.8%
31-35 años	9	3.4%
Mas de 35 años	30	11.2%
Total	268	100%
Ingresos familiares	Frecuencia	Porcentaje
\$400-800	193	72.1%
\$800-1.600	62	23.1%
\$1.600-2.600	11	4.1%
\$2.600 o más	2	0.7%
Total	268	100%

Fuente: elaboración propia.

El análisis de resultados se desarrolla en dos fases:

La primera fase se evaluó la fiabilidad de los instrumentos utilizados mediante el coeficiente alfa de Cronbach. Este coeficiente mide la consistencia interna de los ítems de una escala, y un valor superior a 0.7 indica una alta fiabilidad. Además, se utilizaron otros índices para evaluar la fiabilidad del modelo, incluyendo la ρ_A de Dijkstra y Henseler (2015) y la ρ_C de Jöreskog (1971) (Guaquiza-Leiva *et al.*, 2022).

Tabla 2. Fiabilidad y AVE

	Cronbach's alpha	Composite reliability (rho_a)	Composite reliability (rho_c)	Average variance extracted (AVE)
CO	0.890	0.892	0.932	0.820
HA	0.891	0.903	0.919	0.694
IU	0.820	0.824	0.893	0.735
ME	0.950	0.951	0.962	0.834
MI	0.902	0.904	0.939	0.837
NS	0.807	0.829	0.871	0.630

Fuente: elaboración propia.

La validez convergente es un aspecto crucial en la evaluación del modelo de medición, ya que determina si los indicadores están adecuadamente relacionados con el constructo al que pertenecen. La validez convergente se calcula mediante dos índices principales: las cargas externas de cada indicador y el valor de la varianza media extraída (AVE) para cada constructo. Las cargas externas miden la fuerza de la relación entre cada indicador y el constructo correspondiente. Se considera que un indicador tiene una carga externa adecuada si su valor es mayor a 0.708. El AVE refleja la proporción de la varianza de los indicadores explicada por el constructor y se debe considerar válido si el AVE supera el umbral de 0.50 (Coughlan, 2007).

Los resultados del estudio (tabla 2 y 3) muestran que los indicadores cumplen con estos criterios.

Tabla 3. Cargas externas

	CO	HA	IU	ME	MI	NS
CO1	0.883					
CO2	0.916					
CO3	0.918					
HA1		0.836				
HA2		0.835				
HA3		0.830				
HA4		0.854				
HA5		0.808				
IU1			0.853			
IU2			0.891			
IU3			0.828			

	CO	HA	IU	ME	MI	NS
ME1						
ME2						
ME3						
ME4						
ME5						
MI1					0.880	
MI2					0.935	
MI3					0.928	
NS1						0.807
NS2						0.855
NS3						0.714
NS4						0.792

Fuente: elaboración propia.

La validez discriminante asegura que los constructos en un modelo de medición estén adecuadamente diferenciados entre sí y no estén excesivamente correlacionados. Esta validez se evalúa mediante la matriz Fornell-Larcker, en la que los valores en la diagonal, que representan la raíz cuadrada del valor de la varianza media extraída (AVE) de cada constructo, deben ser superiores a los valores en las mismas columnas y filas que muestran las correlaciones entre los constructos (Gao, 2024).

Los resultados mostrados en la Tabla 4 indican que los valores en la diagonal, correspondientes a la raíz cuadrada del AVE, son mayores que las correlaciones entre los constructos. Esto confirma que el modelo cumple con los requisitos de validez discriminante, asegurando que los constructos están adecuadamente diferenciados y no están excesivamente correlacionados.

Tabla 4. Matrix Fornell-Larcker

	CO	HA	IU	ME	MI	NS
CO	0.906					
HA	0.632	0.833				
IU	0.766	0.670	0.857			
ME	0.797	0.784	0.780	0.913		
MI	0.803	0.745	0.790	0.879	0.915	
NS	0.651	0.733	0.612	0.755	0.722	0.794

Fuente: elaboración propia.

La prueba de hipótesis en el análisis de resultados se centra en evaluar si las relaciones propuestas entre variables en el modelo son significativas. En la segunda fase del análisis, se ha aplicado un enfoque en dos aspectos principales: primero, la prueba de hipótesis y, segundo, el análisis de la capacidad predictiva del modelo. Para llevar a cabo la prueba de hipótesis, se utilizó la técnica estadística no paramétrica de Bootstrapping. Este método permite estimar la significancia de los parámetros del modelo al calcular el valor p asociado a cada hipótesis. El valor p representa la probabilidad de obtener los resultados observados si la hipótesis nula fuera cierta. Para aceptar una hipótesis, el valor p debe ser inferior a 0.05 (Razak *et al.*, 2018).

Los resultados de la prueba de hipótesis, presentados en la Tabla 4, muestran que algunas relaciones entre las variables tienen valores p menores a 0.05, confirmando la significancia estadística de las hipótesis evaluadas y demostrando la capacidad predictiva del modelo.

Tabla 5. Bootstrapping

		Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics (O/STDEV)	P values
H1	IU -> CO	0.293	0.302	0.075	3.887	0.000
H2	MI-> IU	0.446	0.439	0.100	4.477	0.000
H3	MI -> CO	0.320	0.330	0.121	2.643	0.008
H4	ME -> IU	0.338	0.349	0.112	3.009	0.003
H5	ME -> CO	0.301	0.269	0.142	2.116	0.034
H6	HA -> IU	0.100	0.094	0.069	1.447	0.148
H7	HA -> CO	-0.106	-0.092	0.086	1.230	0.219
H8	NS -> IU	-0.038	-0.036	0.058	0.655	0.513
H9	NS -> CO	0.091	0.094	0.074	1.227	0.220

Fuente: elaboración propia.

Finalmente, la capacidad predictiva se evalúa el coeficiente R^2 que interpreta la cantidad de varianza de las variables endógenas explicada por el modelo. En el análisis del comportamiento del consumidor, se consideran aceptables valores de 0.2, y en algunos casos se aceptan valores mínimos de 0.1. Los valores de 0.25, 0.50 y 0.75 se consideran débiles, moderados y fuertes respectivamente para R^2 (Sarango et al., 2024). Los resultados de la Tabla 6 muestran valores entre moderado y fuerte para ambas variables endógenas.


Tabla 6. R^2

	R-square	R-square adjusted
CO	0.714	0.707
IU	0.660	0.653

Fuente: elaboración propia.

En la figura 2 se presenta el modelo con los resultados.

Figura 2. Modelo teórico estructural con resultados



Nota: El nivel de significancia viene dada por: (***: $p < 0.001$; **: $p < 0.01$; *: $p < 0.05$; en cursiva no significativo).

Fuente: elaboración propia.

Discusión

El propósito de esta investigación es explorar cómo la IA influye en el comportamiento y la intención de uso entre estudiantes, considerando factores como la motivación intrínseca, motivación extrínseca, las habilidades y las normas subjetivas. En esta discusión, se hace énfasis en los resultados obtenidos a partir del análisis mediante SEM-PLS, con un enfoque en la validez de las hipótesis planteadas.

La motivación intrínseca y la intención de uso de la inteligencia artificial (IA) están estrechamente relacionadas, como muestran los resultados del estudio. La motivación intrínseca, entendida como el placer y la satisfacción derivados del uso de la tecnología, ejerce una influencia positiva en la intención de uso de la IA (Martín-Núñez *et al.*, 2023). Este hallazgo apoya la teoría de la autodeterminación, que sostiene que una mayor motivación intrínseca fomenta una mayor disposición para adoptar nuevas tecnologías. Además, la motivación intrínseca, también impacta positivamente en el comportamiento de uso de la IA, subrayando su importancia no solo en la intención de uso sino en el uso real de la tecnología (Z. Liu *et al.*, 2023). Esto indica que, para promover un uso sostenido de la IA, es crucial fomentar la motivación intrínseca entre los estudiantes.

El análisis de la motivación extrínseca y su efecto en la intención de uso de la IA muestra una relación positiva significativa. La motivación extrínseca, que incluye recompensas y reconocimientos externos, tiene un impacto positivo en la intención de uso de la IA, sugiriendo que las recompensas externas pueden aumentar la disposición de los estudiantes para utilizar esta tecnología (Lai *et al.*, 2023). La motivación extrínseca influye positivamente en el comportamiento de la IA, apoyando la idea de que las recompensas externas fomentan la intención de uso y la adopción real de la tecnología (Hoces, 2023). Estos hallazgos destacan la importancia de las recompensas externas en la promoción de la tecnología.

El estudio también evaluó el impacto de las habilidades en la intención de uso y el comportamiento de uso de la IA. Aunque se esperaba que las habilidades influyeran significativamente en la intención de uso de la IA, los resultados no confirmaron esta hipótesis. Esto sugiere que, a pesar de las habilidades tecnológicas, los estudiantes no necesariamente muestran una mayor intención de uso de la IA (Chiu *et al.*, 2023). De igual forma las habilidades no demostraron tener un impacto significativo en el comportamiento de uso de la IA. Esto indica que, aunque los estudiantes puedan tener las habilidades necesarias, otros factores pueden ser más determinantes en el uso real de la IA (Jang *et al.*, 2021)

Las normas subjetivas y su impacto en la intención de uso y el comportamiento de uso de la IA también fueron analizadas en el estudio. Los resultados revelan que las normas subjetivas no

muestran un efecto significativo en la intención de uso de la IA, indicando que las percepciones sobre la aceptación social o el apoyo de otros no son factores clave en la adopción de la IA en un contexto académico (R. De Liu *et al.*, 2019).

Este hallazgo contrasta con investigaciones anteriores en diferentes contextos, como en la adopción de tecnologías en el ámbito empresarial o en servicios bancarios electrónicos, donde se ha encontrado que las normas subjetivas tienen un impacto significativo (Ho *et al.*, 2020). En esos otros contextos, las normas subjetivas pueden influir más en la adopción de tecnologías debido a factores como las expectativas sociales. Además, las normas subjetivas tampoco influyen significativamente en el comportamiento de uso de la IA en este estudio, lo que sugiere que su impacto puede variar dependiendo del entorno y la tecnología específica evaluada.

El coeficiente de determinación mide qué proporción de la varianza en la variable dependiente es explicada por las variables independientes en un modelo de regresión. Esta medida indica la calidad del ajuste del modelo a los datos observados y refleja la proporción de la variabilidad total que el modelo es capaz de explicar. El cálculo de R^2 se basa en la comparación entre la variabilidad observada en los datos y la variabilidad que el modelo puede explicar, evaluando cómo las predicciones del modelo se ajustan a los datos reales (Gao, 2024). El análisis de la capacidad predictiva del modelo, medido a través del coeficiente R^2 , muestra que los valores obtenidos para las variables endógenas son de moderados a fuertes.

Para el comportamiento de uso e intención de uso, los valores indican que el modelo explica una cantidad significativa de la varianza en ambas variables, lo que respalda la robustez del modelo en predecir el comportamiento y la intención de uso de la IA. La importancia del R^2 radica en su capacidad para reflejar el ajuste y la precisión del modelo, como se ha documentado en la literatura sobre SEM-PLS (Goktas & Dirsehan, 2024).

Conclusión

Este estudio ha proporcionado una visión detallada de cómo la inteligencia artificial influye en el comportamiento y la intención de uso entre los estudiantes universitarios ecuatorianos. Los resultados indican que la intención de uso y el comportamiento de uso están significativamente influenciados por factores motivacionales tanto intrínsecos como extrínsecos. La motivación intrínseca, relacionada con la satisfacción personal y el disfrute del uso de la IA, ha demostrado ser un factor clave tanto para la intención de uso como para el comportamiento de uso real. Asimismo, la motivación extrínseca, impulsada por recompensas externas y reconocimiento, también ha mostrado una influencia positiva significativa en ambos aspectos.

Sin embargo, las habilidades percibidas para utilizar la IA no mostraron una relación directa y significativa con la intención de uso ni con el comportamiento de uso, lo que sugiere que, aunque los estudiantes se sientan competentes, esto no garantiza su disposición a utilizar la tecnología. Además, las normas subjetivas no resultaron ser un factor determinante en la adopción de la IA, indicando que la presión social y las expectativas de los pares no influyen significativamente en las decisiones de los estudiantes para utilizar esta tecnología.

Los hallazgos de este estudio son de particular interés tanto para las autoridades académicas como para los propios estudiantes. Para las autoridades, los resultados sugieren la necesidad de centrarse en los aspectos motivacionales y de habilidades de los estudiantes, tanto intrínsecos como extrínsecos, para promover un mayor uso de la IA. Esto podría incluir el desarrollo de programas y actividades que integren la IA de manera que aumenten la motivación y las habilidades de los estudiantes, mejorando así su colaboración en proyectos académicos. Para los estudiantes, esta investigación serviría de motivación, destacando la importancia de los aspectos motivacionales y de habilidades en la adopción de nuevas tecnologías y alentándolos a explorar y utilizar la IA como herramienta que para su desarrollo académico.

Este estudio se ha centrado en estudiantes universitarios, por lo que sería interesante replicar la investigación en estudiantes de bachillerato para identificar posibles inconsistencias en los resultados o relaciones significativas. Esto permitiría crear políticas y programas educativos más inclusivos y adaptados a las necesidades específicas de cada grupo, mejorando así la integración de la IA en la educación. Además, la investigación abordó la IA de manera general, sin especificar una tecnología particular. Dado el rápido avance en el campo de la IA, sería relevante seleccionar una IA específica para realizar análisis comparativos y determinar si los resultados son consistentes con esta investigación. Esto permitiría identificar si algunas tecnologías de IA destacan por su capacidad para desarrollar la motivación en los estudiantes.

Declaración de contribución de autoría CRediT

Romero C. Génesis-Paulete: Conceptualización, investigación, administración del proyecto, recursos, visualización, redacción borrador original.

Dilia M. Tivillin-Gutama: Contribución realizada al artículo: Contribución realizada al artículo: Conceptualización, investigación, metodología, administración del proyecto, recursos, visualización, redacción borrador original.

Lorenzo Bonisoli: Contribución realizada al artículo: Curación de datos, análisis formal, metodología, administración del proyecto, recursos, software, supervisión, validación, redacción (revisión y edición).

Declaración de conflictos de interés

Los autores declaran no tener ningún conflicto de intereses.

Referencias

1. Ajzen, I. (2020). The theory of planned behavior: Frequently asked questions. *Human Behavior and Emerging Technologies*, 2(4), 314–324. <https://doi.org/10.1002/hbe2.195>
2. Amani, S., White, L., Balart, T., Arora, L., Shryock, K. J., Brumbelow, K., & Watson, K. L. (n.d.). Generative AI Perceptions: A Survey to Measure the Perceptions of Faculty, Staff, and Students on Generative AI Tools in Academia. *arXiv preprint arXiv:2304.14415*.
3. Belanger, F., & Crossler, R. E. (2019). Dealing with digital traces: Understanding protective behaviors on mobile devices. *Journal of Strategic Information Systems*, 28(1), 34–49. <https://doi.org/10.1016/j.jsis.2018.11.002>
4. Brachten, F., Kissmer, T., & Stieglitz, S. (2021). The acceptance of chatbots in an enterprise context – A survey study. *International Journal of Information Management*, 60. <https://doi.org/10.1016/j.ijinfomgt.2021.102375>
5. Carranza, R., Díaz, E., Sánchez-Camacho, C., & Martín-Consuegra, D. (2021). e-Banking Adoption: An Opportunity for Customer Value Co-creation. *Frontiers in Psychology*, 11, 621248. <https://doi.org/10.3389/fpsyg.2020.621248>
6. Chan, C. K. Y., & Lee, K. K. W. (2023). The AI generation gap: Are Gen Z students more interested in adopting generative AI such as ChatGPT in teaching and learning than their Gen X and millennial generation teachers? *Smart Learning Environments*, 10(1), 60. <https://doi.org/10.1186/s40561-023-00269-3>
7. Chaurasia, S. S., Verma, S., & Singh, V. (2019). Exploring the intention to use M-payment in India: Role of extrinsic motivation, intrinsic motivation and perceived demonetization regulation. *Transforming Government: People, Process and Policy*, 13(3–4), 276–305. <https://doi.org/10.1108/TG-09-2018-0060>
8. Chiu, T. K. F., Xia, Q., Zhou, X., Chai, C. S., & Cheng, M. (2023). Systematic literature review on opportunities, challenges, and future research recommendations of artificial intelligence in education. *Computers and Education: Artificial Intelligence*, (4), 100118. <https://doi.org/10.1016/j.caeai.2022.100118>
9. Christino, J. M. M., Cardozo, É. A. A., Petrin, R., & de Aguiar Pinto, L. H. (2021). Fatores que influenciam a intenção e o comportamento de uso de aplicativos de delivery

- para restaurantes. *Revista Brasileira de Gestao de Negocios*, 23(1), 21–42. <https://doi.org/10.7819/rbgn.v23i1.4095>
10. Coughlan, J. (2007). *Structural Equation Modeling: Guidelines for Determining Model Fit*. <https://www.researchgate.net/publication/254742561>
 11. Deci, E. L., & Ryan, R. M. (2000). The “what” and “why” of goal pursuits: Human needs and the self-determination of behavior. *Psychological Inquiry*, 11(4), 227–268. https://doi.org/10.1207/S15327965PLI1104_01
 12. Dwivedi, Y. K., Rana, N. P., Jeyaraj, A., Clement, M., & Williams, M. D. (2019). Re-examining the Unified Theory of Acceptance and Use of Technology (UTAUT): Towards a Revised Theoretical Model. *Information Systems Frontiers*, 21(3), 719–734. <https://doi.org/10.1007/s10796-017-9774-y>
 13. Gao, J. (2024). R-Squared (R^2) – How much variation is explained? . *Research Methods in Medicine & Health Sciences*, 5(4), 104–109. <https://doi.org/10.1177/26320843231186398>
 14. Goktas, P., & Dirsehan, T. (2024). Using PLS-SEM and XAI for casual-predictive services marketing research. *Journal of Services Marketing*, 39(1). <https://doi.org/10.1108/JSM-10-2023-0377>
 15. Guanaquiza-Leiva, M., Espinoza-Saraguro, D., & Bonisoli, L. (2022). Análisis de los factores ambientales en la decisión de compra de los productos orgánicos en el consumidor ecuatoriano. *593 Digital Publisher CEIT*, 7(2), 247–259. <https://doi.org/10.33386/593dp.2022.2.1026>
 16. Ho, J. C., Wu, C. G., Lee, C. S., & Pham, T. T. T. (2020). Factors affecting the behavioral intention to adopt mobile banking: An international comparison. *Technology in Society*, 63. <https://doi.org/10.1016/j.techsoc.2020.101360>
 17. Hoces, Z. (2023). *Motivación y estrategias de aprendizaje en educación universitaria*. Instituto Universitario de Innovación Ciencia y Tecnología Inudi Perú. <https://doi.org/10.35622/inudi.b.117>
 18. Jang, M., Aavakare, M., Nikou, S., & Kim, S. (2021). The impact of literacy on intention to use digital technology for learning: A comparative study of Korea and Finland. *Telecommunications Policy*, 45(7). <https://doi.org/10.1016/j.telpol.2021.102154>

19. Kusumawati, M. D., Fauziddin, M., & Ananda, R. (2023). The Impact of Reward and Punishment on the Extrinsic Motivation of Elementary School Students. *AL-ISHLAH: Jurnal Pendidikan*, 15(1), 183–192. <https://doi.org/10.35445/alishlah.v15i1.2856>
20. Lai, C. Y., Cheung, K. Y., & Chan, C. S. (2023). Exploring the role of intrinsic motivation in ChatGPT adoption to support active learning: An extension of the technology acceptance model. *Computers and Education: Artificial Intelligence*, 5, 100178. <https://doi.org/10.1016/j.caeai.2023.100178>
21. Leong, L. Y., Hew, T. S., Ooi, K. B., Metri, B., & Dwivedi, Y. K. (2023). Extending the Theory of Planned Behavior in the Social Commerce Context: A Meta-Analytic SEM (MASEM) Approach. *Information Systems Frontiers*, 25(5), 1847–1879. <https://doi.org/10.1007/s10796-022-10337-7>
22. Liu, R. De, Wang, J., Gu, D., Ding, Y., Oei, T. P., Hong, W., Zhen, R., & Li, Y. M. (2019). The effect of parental phubbing on teenager's mobile phone dependency behaviors: The mediation role of subjective norm and dependency intention. *Psychology Research and Behavior Management*, 12, 1059–1069. <https://doi.org/10.2147/PRBM.S224133>
23. Liu, Z., Wang, S., & Gu, Q. (2023). Study on the Mechanism of Influencing Adolescents' Willingness to Participate in Ice Sports. *Children*, 10(6), 1080. <https://doi.org/10.3390/children10061080>
24. Malek, S. L., Sarin, S., & Haon, C. (2020). Extrinsic Rewards, Intrinsic Motivation, and New Product Development Performance. *Journal of Product Innovation Management*, 37(6), 528–551. <https://doi.org/10.1111/jpim.12554>
25. Martín-Núñez, J. L., Ar, A. Y., Fernández, R. P., Abbas, A., & Radovanović, D. (2023). Does intrinsic motivation mediate perceived artificial intelligence (AI) learning and computational thinking of students during the COVID-19 pandemic? *Computers and Education: Artificial Intelligence*, 4, 100128. <https://doi.org/10.1016/j.caeai.2023.100128>
26. Montalván-Vélez, C. L., Mogrovejo-Zambrano, J. N., Rodríguez-Andrade, A. E., & Andrade-Vaca, A. L. (2024). Adopción y Efectividad de Tecnologías Emergentes en la Educación desde una Perspectiva Administrativa y Gerencial. *Journal of Economic and Social Science Research*, 4(1), 160–172. <https://doi.org/10.55813/gaea/jessr/v4/n1/92>
27. Nguyen, G. N., & Ho, T. T. H. (2022). Interplay between subjective norm, emotions, and purchase intention towards foreign brands: evidence from Vietnam. *Innovative Marketing*,

- 18(1), 79–93. [https://doi.org/10.21511/im.18\(1\).2022.07](https://doi.org/10.21511/im.18(1).2022.07)
28. Perri, C., Giglio, C., & Corvello, V. (2020). Smart users for smart technologies: Investigating the intention to adopt smart energy consumption behaviors. *Technological Forecasting and Social Change*, 155. <https://doi.org/10.1016/j.techfore.2020.119991>
29. Razak, N. I. A., Zamzuri, Z. H., & Suradi, N. R. M. (2018). Bootstrapping technique in structural equation modeling: A Monte Carlo study. *Journal of Physics: Conference Series*, 1132(1). <https://doi.org/10.1088/1742-6596/1132/1/012072>
30. Rochina Chileno, S. C., Duarte Mora, M. J., Macanchí Pico, M. L., & Tipantuña Soria, E. G. (2024). Transformación educativa en el siglo XXI: Integración de Tecnologías Emergentes para el Aprendizaje Efectivo. *Reincisol.*, 3(6), 6092–6109. [https://doi.org/10.59282/reincisol.V3\(6\)6092-6109](https://doi.org/10.59282/reincisol.V3(6)6092-6109)
31. Sarango, E., Vásquez, F., & Bonisoli, L. (2024). Responsabilidad social corporativa y lealtad a la marca: un análisis empírico. *Journal Business Science*, 5(1), 53–68. <https://doi.org/10.56124/jbs.v5i1.004>
32. Seo, K., Tang, J., Roll, I., Fels, S., & Yoon, D. (2021). The impact of artificial intelligence on learner–instructor interaction in online learning. *International Journal of Educational Technology in Higher Education*, 18(1). <https://doi.org/10.1186/s41239-021-00292-9>
33. Shneor, R., & Munim, Z. H. (2019). Reward crowdfunding contribution as planned behaviour: An extended framework. *Journal of Business Research*, 103, 56–70. <https://doi.org/10.1016/j.jbusres.2019.06.013>
34. Singh, A., Sharma, S., & Paliwal, M. (2020). Adoption intention and effectiveness of digital collaboration platforms for online learning: the Indian students’ perspective. *Interactive Technology and Smart Education*, 18(4), 493–514. <https://doi.org/10.1108/ITSE-05-2020-0070>
35. Strzelecki, A. (2023). Students’ Acceptance of ChatGPT in Higher Education: An Extended Unified Theory of Acceptance and Use of Technology. *Innovative Higher Education*. <https://doi.org/10.1007/s10755-023-09686-1>
36. Tilibaşa, M. A., Bonciliacă, A. N., Popa, I., Ştefan, S. C., & Tărăban, I. (2023). Implications of digital risks on teachers’ motivation and intention to use digital tools: a PLS-POS perspective in Romanian preuniversity education system. *Kybernetes*, 52(13), 45–60.

<https://doi.org/10.1108/K-06-2023-1116>

37. Urhahne, D., & Wijnia, L. (2023). Theories of Motivation in Education: an Integrative Framework. *Educational Psychology Review*, 35(2), 45. <https://doi.org/10.1007/s10648-023-09767-9>
38. Wang, Y. M., Wei, C. L., Lin, H. H., Wang, S. C., & Wang, Y. S. (2022). What drives students' AI learning behavior: a perspective of AI anxiety. *Interactive Learning Environments*, 32(6), 2584–2600. <https://doi.org/10.1080/10494820.2022.2153147>
39. Wu, C. H., Liu, C. H., & Huang, Y. M. (2022). The exploration of continuous learning intention in STEAM education through attitude, motivation, and cognitive load. *International Journal of STEM Education*, 9(1). <https://doi.org/10.1186/s40594-022-00346-y>
40. Xu, L., Zhang, J., Ding, Y., Zheng, J., Sun, G., Zhang, W., & Philbin, S. P. (2023). Understanding the role of peer pressure on engineering students' learning behavior: A TPB perspective. *Frontiers in Public Health*, 10, 1069384. <https://doi.org/10.3389/fpubh.2022.1069384>
41. Yin, J., Goh, T. T., Yang, B., & Xiaobin, Y. (2021). Conversation Technology With Micro-Learning: The Impact of Chatbot-Based Learning on Students' Learning Motivation and Performance. *Journal of Educational Computing Research*, 59(1), 154–177. <https://doi.org/10.1177/0735633120952067>
42. Zacccone, M. C., & Pedrini, M. (2019). The effects of intrinsic and extrinsic motivation on students learning effectiveness. Exploring the moderating role of gender. *International Journal of Educational Management*, 33(6), 1381–1394. <https://doi.org/10.1108/IJEM-03-2019-0099>
43. Zarouali, B., Van Den Broeck, E., Walrave, M., & Poels, K. (2018). Predicting Consumer Responses to a Chatbot on Facebook. *Cyberpsychology, Behavior, and Social Networking*, 21(8), 491–497. <https://doi.org/10.1089/cyber.2017.0518>

Constructo	Indicadores	Fuentes
Apéndice 1. IU - Intención de Uso	IU1 - Yo recomendaría el uso de la IA a mis amigos para mejorar su rendimiento académico. IU2 - Utilizaría aplicaciones de la IA para optimizar mi aprendizaje. IU3 - Quiero utilizar constantemente aplicaciones de la IA.	(Yu <i>et al.</i> , 2021)
CO – Comportamiento de Uso	CO1 - Sugiero la IA a mis amigos para mejorar sus notas. CO2 - Uso la IA en todas las oportunidades disponibles. CO3 - Por lo general uso la IA en mi estudio.	(Yu <i>et al.</i> , 2021)
MI – Motivación Intrínseca	MI1 - Me complace explorar nuevas maneras de emplear la IA para optimizar mi rendimiento académico y apoyar mi proceso de aprendizaje como estudiante. MI2 - Estoy satisfecho en utilizar la IA para mejorar la calidad de mis estudios. MI3 - Estoy contento al incorporar herramientas de IA en mis tareas. MI4 - Estoy de acuerdo contribuir al avance académico a través del uso de la IA.	(Hasbullah <i>et al.</i> , 2022)
ME - Motivación Extrínseca	ME1 - Descubrí que el uso de herramientas de IA para personalizar mi experiencia de aprendizaje es útil. ME2 - Descubrí que gestionar mi progreso académico a través de sistemas de IA es sencillo. ME3 - La IA permite un aprendizaje más rápido y adaptado a mis necesidades. ME4 - La IA hace que sea más fácil acceder a mis recursos educativos. ME5 - Pienso que es eficiente usar IA.	(Chaurasia <i>et al.</i> , 2019b)
OP - Oportunidades	OP1 - La IA me ayuda en el cumplimiento de mis tareas. OP2 - Creo que utilizo la IA como herramienta porque me permite una búsqueda rápida. OP3 - Confío en la información proporcionada por la IA. OP4 - Uso herramientas de búsqueda avanzada basadas en IA para agilizar el proceso de búsqueda. OP5 - La IA permite que los estudiantes tengan información más confiable.	(Hasbullah <i>et al.</i> , 2022)
HA - Habilidades	HA1 - Aprender habilidades relacionadas con la IA es fácil para mí. HA2 - No creo que me falte el potencial para aprender habilidades relacionadas con la IA. HA3 - No creo que me falte el conocimiento para el aprendizaje de habilidades relacionadas con la IA. HA4 - No tengo miedo de aprender habilidades relacionadas con la IA. HA5 - Tengo suficiente inteligencia para aprender habilidades relacionadas con la IA.	(Wang <i>et al.</i> , 2022)
NS – Normas Subjetivas	31. NS1 - Las personas que influyen en mi comportamiento piensan que debería usar la IA. 32. NS2 - Si las personas que me rodean usan la IA, esto me impulsará a utilizar también. 33. NS3 - Las personas que tienen influencia sobre mí (como familiares y amigos) influyen en mi decisión de adoptar la IA en mis propios estudios. 34. NS4 - EL contenido educativo creado por IA en plataformas en línea puede animarme a usar esta herramienta para mejorar mi comprensión de los temas de estudio.	(Strzelecki, 2023b) (Nguyen & Ho, 2022b)

Fuente: elaboración propia.