

Impact of Artificial Intelligence on Autonomous Learning of University Students

Impacto De La Inteligencia Artificial En El Aprendizaje Autónomo De Estudiantes Universitarios

Autores:

Guevara-Reyes, Rodrigo Josué
Universidad Estatal de Milagro
MSc. Sistemas de Información Mención en inteligencia de negocios
y analítica de datos masivos
Docente tutor en el área de Inteligencia Artificial
Milagro – Ecuador



rguevarar@unemi.edu.ec



<https://orcid.org/0009-0009-7575-6148>

Saltos-Verdezoto, Yajaira Marianela
UNIVERSIDAD ESTATAL DE MILAGRO
Maestrante



ysaltosv@unemi.edu.ec



<https://orcid.org/0009-0001-4081-9024>

Montero-Garofalo, Maria Fernanda
UNIVERSIDAD ESTATAL DE MILAGRO
Maestrante



mmonterog@unemi.edu.ec



<https://orcid.org/0009-0002-3802-1440>

Ordóñez-Vargas, Alfredo Ecuador
UNIVERSIDAD ESTATAL DE MILAGRO
Maestrante



aordonezv3@unemi.edu.ec



<https://orcid.org/0009-0003-9658-5970>

Fechas de recepción: 04-AGO-2025 aceptación: 04-SEP-2025 publicación: 30-SEP-2025



<https://orcid.org/0000-0002-8695-5005>

<http://mqrinvestigar.com/>



Resumen

El presente estudio, analiza el impacto de la inteligencia artificial (IA) en el aprendizaje autónomo de estudiantes universitarios, integrando el Modelo de Expectativa-Confirmación (ECM). Aplicando un diseño cuantitativo, no experimental y de corte transversal, y utilizando un cuestionario con escalas tipo Likert, se encuestó a una de 350 estudiantes, para posteriormente realizar el análisis de datos, utilizando la técnica PLS-SEM, con el software SmartPLS, versión 4. Las escalas mostraron adecuada fiabilidad y validez ($\alpha \geq .834$; $CR \geq .913$; $AVE \geq .740$); y los resultados indicaron que la utilidad percibida incrementa significativamente la satisfacción, así como la confirmación de expectativas. A su vez, la satisfacción es el predictor más robusto de la intención de continuidad en el uso de IA para el aprendizaje autónomo. Por otra parte, la relación directa entre utilidad percibida e intención no fue significativa, sugiriendo un efecto indirecto mediado por la satisfacción. Teóricamente, se refuerza la pertinencia del ECM para contextos educativos mediados por IA y se evidencia el papel central de la satisfacción. A nivel práctico, los hallazgos recomiendan implementar soluciones de IA que alineen expectativas y experiencia de uso, con retroalimentación oportuna, personalización y apoyo a la autorregulación.

Palabras clave: inteligencia artificial; aprendizaje autónomo; satisfacción; intención de uso de IA

Abstract

This study examines the impact of artificial intelligence (AI) on university students' self-directed learning using the Expectation–Confirmation Model (ECM). A quantitative, cross-sectional design was employed with a Likert-type survey administered to 350 students; the structural model was estimated through PLS-SEM, with SmartPLS 4. Measurement quality was adequate and findings show that perceived usefulness significantly increases satisfaction and expectation confirmation also enhances satisfaction. In turn, satisfaction strongly predicts continuance intention to use AI for self-directed learning. Conversely, the direct path from perceived usefulness to intention was not significant, indicating an indirect effect via satisfaction. Theoretically, results support the applicability of ECM in AI-mediated educational contexts and underscore the central role of satisfaction. Practically, institutions should deploy AI solutions that align expectations with user experience, providing timely feedback, personalization, and self-regulation support to foster sustained adoption.

Keywords: artificial intelligence; self-directed learning; satisfaction; continuance intention to use IA

Introducción

En la última década, la inteligencia artificial (IA) ha irrumpido con fuerza en el ámbito de la educación superior, redefiniendo los entornos de enseñanza y aprendizaje. A través de herramientas como tutores inteligentes, sistemas adaptativos, asistentes conversacionales y plataformas generativas, ha facilitado una educación más personalizada, flexible y centrada en el estudiante, configurándose así, como una herramienta tecnológica disruptiva que promete transformar la forma en que los estudiantes gestionan sus procesos de aprendizaje, a través de entornos personalizados, adaptativos y accesibles (Gotavade, 2024; Younas et al., 2025). Este avance ha sido especialmente relevante en el fortalecimiento del aprendizaje autónomo, al proporcionar retroalimentación instantánea, rutas personalizadas y recursos adecuados al ritmo individual de los estudiantes universitarios (Gutiérrez-Castillo et al., 2025). El aprendizaje autónomo (AA) ha sido históricamente reconocido como una competencia esencial para los estudiantes universitarios en contextos de educación superior, dado su impacto positivo en el rendimiento académico, la motivación intrínseca y el desarrollo de habilidades de autorregulación (Huang et al., 2022). Plataformas basadas en IA, como tutores virtuales, sistemas de recomendación y asistentes conversacionales, han demostrado su potencial para fortalecer la autonomía del estudiante al ofrecer retroalimentación inmediata, planificación personalizada y apoyo constante (Zhou & Zhang, 2024; Wu et al., 2024). Sin embargo, el impacto real de estas tecnologías sobre el aprendizaje autónomo aún necesita mayor comprensión empírica y teórica.

Si bien existe un creciente cuerpo de literatura que documenta los beneficios de la IA en entornos educativos, aún persisten vacíos importantes en cuanto a su relación directa con el desarrollo de habilidades de aprendizaje autónomo, especialmente en estudiantes universitarios. La mayoría de los estudios existentes se centran en tecnologías específicas o resultados aislados, dejando de lado análisis integrales sobre cómo la IA puede fomentar la motivación, la autorregulación y la toma de decisiones independiente en los estudiantes (Younas et al., 2025; Avramenko & Bulanova, 2024). Asimismo, pocos trabajos consideran factores moderadores como el apoyo docente, la autoeficacia o la aceptación tecnológica, aspectos clave para entender cómo se configura la autonomía del aprendizaje en contextos mediados por IA (Wu et al., 2024; Zhou & Zhang, 2024). Esta investigación es, por tanto,



necesaria para llenar ese vacío, proporcionando evidencia que vincule la adopción de tecnologías de IA, con el fortalecimiento del aprendizaje autónomo, desde un enfoque integral e interdisciplinario.

La presente investigación tiene como objetivo principal analizar el impacto de la integración de herramientas de IA en el fortalecimiento del aprendizaje autónomo de los estudiantes universitarios. Para ello, se plantean las siguientes preguntas: ¿De qué manera las plataformas educativas basadas en IA influyen en las estrategias de aprendizaje autónomo de los estudiantes? El estudio se desarrollará mediante un enfoque cuantitativo, con aplicación de encuestas a estudiantes universitarios.

Los resultados de esta investigación aportarán a la literatura académica una comprensión más profunda sobre el rol de la inteligencia artificial como catalizador del aprendizaje autónomo en la educación superior. A nivel teórico, se propone un modelo integrador basado en la teoría de la autodeterminación y la aceptación tecnológica, que podrá ser validado y replicado en estudios posteriores. En términos prácticos, los hallazgos permitirán a diseñadores instruccionales, docentes y responsables de política educativa tomar decisiones informadas sobre la adopción e implementación de tecnologías inteligentes, promoviendo entornos de aprendizaje más autónomos, personalizados y sostenibles (Blancas Sánchez et al., 2024; Xia et al., 2022).

2. Revisión de Literatura

La Inteligencia Artificial (IA) se ha configurado como un catalizador que promueve una transformación en el ámbito del aprendizaje autónomo de estudiantes universitarios, redefiniendo los modelos pedagógicos tradicionales. Su implementación no solo afecta la manera en la que se imparte la enseñanza, sino también cómo los alumnos se involucran con los contenidos, desarrollan habilidades metacognitivas y fortalecen su capacidad para aprender de manera independiente. La IA permite que los estudiantes gestionen su tiempo, ritmo y secuencia de aprendizaje, promoviendo una cultura de responsabilidad y autorregulación. Según Quinde et al. (2024), los sistemas basados en IA pueden personalizar la experiencia educativa, lo que fomenta la autonomía en el aprendizaje al proporcionar retroalimentación inmediata y adaptativa; en este estudio se destaca que el uso de herramientas de IA permite a los estudiantes definir su propia trayectoria educativa,

seleccionando contenidos de acuerdo con sus necesidades específicas y fomentando competencias como la búsqueda autónoma de información, el pensamiento crítico y la capacidad para resolver problemas de forma independiente.

Además, la IA proporciona métodos innovadores de evaluación del aprendizaje que permiten a los docentes obtener una visión más dinámica, profunda y personalizada del progreso estudiantil. Según Bao (2024), estos sistemas van más allá de las evaluaciones tradicionales al utilizar algoritmos de análisis de datos que identifican patrones de conducta, niveles de desempeño y áreas de mejora en tiempo real; una capacidad analítica que transforma el rol del docente, ya que le brinda información valiosa para tomar decisiones pedagógicas basadas en evidencias concretas y actualizadas. Al mismo tiempo, este enfoque mejora la calidad de la enseñanza, al permitir intervenciones tempranas y más efectivas, lo cual promueve un mayor empoderamiento de los estudiantes al ofrecerles un mayor control sobre su aprendizaje, mediante trayectorias formativas que se ajustan a sus estilos cognitivos, intereses y niveles de competencia. En este sentido, Feng et al. (2023) señalan que las rutas de aprendizaje individualizadas impulsadas por IA, han demostrado ser altamente eficaces en entornos de educación superior, donde la diversidad de perfiles estudiantiles exige estrategias pedagógicas más flexibles y centradas en el estudiante.

Sin embargo, la implementación de la IA en la educación también plantea desafíos significativos, especialmente en términos de ética, privacidad y transparencia algorítmica. Es fundamental que los educadores analicen cómo esta tecnología redefine su rol en el aula, pasando de ser transmisores de conocimiento a facilitadores del aprendizaje guiado por datos; además de las implicaciones que tiene delegar decisiones pedagógicas a sistemas automatizados. Макаренко et al. (2024) subrayan la necesidad de desarrollar marcos normativos que regulen el uso ético de la IA en contextos educativos, garantizando la protección de los datos personales de los estudiantes; así como la equidad en el acceso a estas tecnologías. Por otra parte, de acuerdo con AL-Tkhayneh et al. (2023), aunque muchos estudiantes valoran positivamente el uso de IA como un medio para enriquecer su experiencia de aprendizaje, también existen preocupaciones sobre la posible pérdida de habilidades humanas, la despersonalización de la educación y la dependencia excesiva de la tecnología.

Bajo este contexto, se evidencia que, en la literatura académica respecto a este tema, se sugiere que la IA no solo transforma la enseñanza y el aprendizaje en sí, sino que también promueve una cultura de colaboración y aprendizaje continuo entre estudiantes y docentes. En esta nueva dinámica educativa, los profesores pueden apoyarse en la IA para diseñar estrategias pedagógicas más efectivas y centradas en el estudiante, mientras que los alumnos pueden utilizar estas herramientas como aliados en su proceso de formación. Según Salas-Pilco y Yang (2022), la integración de la IA favorece el trabajo colaborativo mediante plataformas que fomentan el intercambio de ideas, el aprendizaje entre pares y la co-creación de conocimiento. No obstante, para que este potencial se materialice, es imprescindible que las instituciones educativas comprendan a fondo las implicaciones técnicas y sociales de estas tecnologías. Han (2019) enfatiza que, al enfrentar los retos de la IA y maximizar sus beneficios, se puede fortalecer la calidad educativa, promover la inclusión y preparar mejor a los estudiantes para desenvolverse en un entorno globalizado y altamente tecnológico.

Con base en esto, se puede concluir que, el impacto de la IA en el aprendizaje autónomo de los estudiantes universitarios es multifacético, abarcando desde la personalización de la enseñanza hasta la promoción de competencias transversales como la autorregulación, el pensamiento crítico y la alfabetización digital. La IA ofrece oportunidades valiosas para transformar positivamente el proceso formativo, pero también exige una gestión cuidadosa y reflexiva por parte de los actores educativos. Por lo tanto, es crucial que los docentes y las instituciones no solo adopten la tecnología, sino que lo hagan con responsabilidad, asegurándose de que su implementación respete principios éticos, fomente la equidad y fortalezca la experiencia educativa en su conjunto.

Para lograr este propósito, este estudio analiza el impacto de la aplicación de la Inteligencia Artificial en el aprendizaje autónomo de estudiantes universitarios, para lo cual, se utilizará como fundamento teórico el Modelo de Expectativa-Confirmación (ECM, por sus siglas en inglés), propuesto por Oliver (1980), un modelo que ha sido ampliamente adoptado como un marco teórico sólido para comprender los factores que influyen en la satisfacción de los usuarios y su disposición a seguir utilizando un producto o servicio, especialmente en contextos mediados por la tecnología. Su relevancia en estudios relacionados con los sistemas de información, ha permitido extender su aplicación a campos como la educación digital,

donde el papel de la IA está creciendo aceleradamente. Este modelo parte de la suposición de que la satisfacción experimentada por el usuario después de haber adoptado una tecnología depende de la comparación entre sus expectativas iniciales y el rendimiento percibido tras su uso. En este sentido, la IA aplicada a la educación superior, puede evaluarse eficazmente mediante el ECM, ya que los estudiantes universitarios forman ciertas expectativas sobre la utilidad, accesibilidad y personalización que estas herramientas pueden ofrecer para favorecer su aprendizaje autónomo, y estas percepciones iniciales son determinantes para su satisfacción posterior y su intención de uso continuo.

De acuerdo con Wang y Li (2024), el modelo ECM, se compone de los siguientes constructos:

- Utilidad Percibida, que hace referencia a cómo los estudiantes evalúan la utilidad real y la eficacia de las herramientas de IA una vez que las han incorporado en sus prácticas educativas. Esta percepción se compara con las expectativas previas y afecta directamente su juicio sobre el valor de la IA. Cuando los estudiantes perciben que la IA les ayuda a planificar, monitorear y evaluar su propio aprendizaje, se genera una valoración positiva del rendimiento, lo cual fortalece su autonomía y compromiso (Zhu et al., 2021).
- Confirmación de Expectativas; una dimensión que evalúa si el uso efectivo de la IA confirma o desilusiona las expectativas iniciales de los estudiantes. Cuando el rendimiento percibido está en consonancia o incluso supera las expectativas, se genera una confirmación positiva que incrementa la satisfacción y consolida la actitud favorable hacia su uso continuo. En cambio, una desconfirmación negativa puede reducir la motivación para seguir empleando estas tecnologías (Baharum et al., 2021).
- Satisfacción, que es el resultado emocional que deriva de comparar expectativas previas con la experiencia real de uso. En este caso, un estudiante satisfecho no solo percibe que la IA cumplió con sus expectativas, sino que también reconoce su valor añadido para facilitar el aprendizaje autónomo. Estudios como el de Baharum et al. (2021) han demostrado que una confirmación positiva impacta significativamente en

la satisfacción del usuario, consolidando una actitud favorable hacia el uso futuro de la tecnología.

- Intención de Comportamiento, que es un constructo que alude a la disposición del usuario para seguir utilizando la tecnología en el futuro. En educación, este aspecto es crucial, ya que una intención de continuidad indica que el estudiante ha interiorizado el uso de IA como parte habitual de su proceso de aprendizaje. Pan et al. (2024) sostienen que esta intención está directamente influida por la satisfacción experimentada, lo cual valida la idea de que estudiantes satisfechos con los resultados obtenidos mediante IA tienden a integrarla de manera más permanente en sus rutinas académicas.

El ECM ha sido aplicado con éxito en diferentes sectores como la educación en línea, la banca digital, el turismo y el comercio electrónico, para entender cómo las expectativas y experiencias de los usuarios determinan su comportamiento de uso continuo. En el caso de las plataformas educativas, el modelo ha permitido evidenciar que la continuidad del uso está directamente vinculada a la confirmación de las expectativas respecto a la utilidad pedagógica del sistema (Dhia & Kholid, 2021; Wang & Wang, 2019). En investigaciones relacionadas con herramientas de IA, esta lógica se mantiene, ya que, los estudiantes deciden continuar usando aplicaciones inteligentes si perciben que estas fortalecen su capacidad para aprender de forma autónoma, tomar decisiones informadas y avanzar a su propio ritmo.

Bajo este contexto, el Modelo de Expectativa-Confirmación ofrece un marco conceptual útil para analizar cómo las herramientas de IA inciden en el aprendizaje autónomo, para lo cual se plantean las siguientes hipótesis:

- H1: La utilidad percibida influye positivamente en la Intención de Continuar utilizando Herramientas de Inteligencia Artificial Generativa para el aprendizaje autónomo
- H2: La utilidad percibida influye positivamente en la satisfacción del uso de Herramientas de Inteligencia Artificial Generativa para el aprendizaje autónomo
- H3: La confirmación de expectativas influye positivamente en la satisfacción del uso de Herramientas de Inteligencia Artificial Generativa para el aprendizaje autónomo



- H4: La satisfacción influye positivamente en la Intención de Continuar utilizando Herramientas de Inteligencia Artificial Generativa para el aprendizaje autónomo

En la Figura 1 se muestra el modelo ECM aplicado a la presente investigación




Figura 1. Modelo ECM

3. Metodología

La presente investigación adoptó un enfoque cuantitativo con el objetivo de analizar el impacto de la inteligencia artificial (IA) en el aprendizaje autónomo de estudiantes universitarios. Se enmarca dentro de un diseño no experimental de tipo transversal, en tanto los datos fueron recolectados en un único momento temporal, sin manipulación de las variables. El alcance del estudio es descriptivo y correlacional, dado que, por un lado, se pretende caracterizar el uso de herramientas de IA y, por otro, establecer relaciones estadísticas entre su utilización y el grado de aprendizaje autónomo declarado por los participantes.

El instrumento de recolección de datos consistió en un cuestionario estructurado, validado previamente por Wang y Li (2024), quienes lo desarrollaron para medir la disposición de los estudiantes universitarios hacia el aprendizaje autónomo asistido por IA. Este instrumento fue adaptado cultural y contextualmente al entorno universitario ecuatoriano mediante un proceso de validación por juicio de expertos, asegurando su pertinencia, claridad y congruencia con los objetivos del estudio. El cuestionario estuvo conformado por ítems en escala Likert de siete puntos, distribuidos en las dimensiones propuestas en el modelo teórico

de Expectativa–Confirmación, con constructos como la utilidad percibida, la confirmación de expectativas, la satisfacción y la intención de continuidad.

La población objetivo estuvo conformada por estudiantes universitarios matriculados entre primer y octavo nivel en las diferentes carreras ofertadas por la Universidad Estatal Amazónica. Se empleó un muestreo probabilístico aleatorio estratificado, con base en la carrera y el nivel de estudios, a fin de garantizar una representatividad proporcional. La muestra obtenida fue de 350 participantes, la cual se considera una muestra aceptable cuando se aplican técnicas de ecuaciones estructurales. Para el análisis de los datos se emplearon técnicas estadísticas tanto descriptivas como inferenciales. Inicialmente, se realizaron análisis de frecuencias, medidas de tendencia central y dispersión para caracterizar las variables. Posteriormente, se aplicó la técnica de modelamiento de ecuaciones estructurales mediante mínimos cuadrados parciales (PLS-SEM), utilizando el software SmartPLS. Esta técnica permitió comprobar empíricamente las relaciones hipotéticas del modelo propuesto, evaluando la validez convergente, discriminante y la confiabilidad de los constructos latentes, así como la significancia de los coeficientes de regresión mediante bootstrapping. Además, esta prueba estadística es bastante robusta y permite el análisis de modelos complejos con muestras relativamente pequeñas.

Análisis de Resultados

Respecto a la caracterización demográfica de los encuestados, la mayoría de los participantes se encuentra en el rango de 18 a 28 años (64.77 %), seguido por el grupo de 28 a 48 años (31.79 %), mientras que los rangos de edad superiores, como 38 a 48 años, 48 a 58 años y 58 o más, representan conjuntamente menos del 5 % de la muestra. Esta distribución sugiere una predominancia de estudiantes adultos jóvenes. Respecto al género, se identificó una mayor participación de mujeres (52.44 %), seguida por hombres (46.13 %), y una minoría que prefirió no declarar su identidad de género (1.43 %). Estos datos permiten observar una leve sobrerrepresentación femenina, alineada con ciertas tendencias actuales en la matrícula universitaria.

Los datos recogidos tras la aplicación de las encuestas se sistematizaron y analizaron utilizando modelos de ecuaciones estructurales con mínimos cuadrados parciales (PLS-SEM por sus siglas en Inglés), utilizando el software SmartPLS versión 4. De acuerdo con Hair et. al. (2017), esta técnica es adecuada para trabajar con muestras pequeñas y modelos complejos; además, permite la verificación de la validez convergente y divergente del modelo, el cual es un paso previo a la comprobación de las hipótesis planteadas en el estudio.

Análisis de Confiabilidad de las Escalas

El análisis del modelo de medición se realiza en varias fases, iniciando con el análisis de la confiabilidad de las escalas, a través del índice del Alpha de Cronbach y el índice de confiabilidad compuesto. Para considerar una escala como confiable, el valor mínimo que deben obtener en estos índices es de 0.7 (Kline, 2023); y, conforme a los resultados que se muestran en la Tabla 1 todos los ítems de cada constructo superan el umbral requerido, por lo que, se puede concluir que las escalas son confiables.

Tabla 1. Fiabilidad de las escalas de cada variable latente

	Alpha de Cronbach	Índice de Confiabilidad Compuesto	<u>Average variance extracted (AVE)</u>
Percepción de Utilidad	0.934	0.935	0.835
Confirmación de Expectativas	0.936	0.941	0.840
Satisfacción	0.935	0.939	0.740
Intención de Uso de IA para Aprendizaje Autónomo	0.834	0.913	0.823

Validez convergente y discriminante

Para garantizar la validez del modelo de medición, se evaluó la validez convergente y discriminante del instrumento. La validez convergente permite verificar que los ítems asociados a un mismo constructo teórico presentan una alta correlación entre sí, lo cual

permite concluir que los ítems miden adecuadamente el constructo teórico. La validez convergente fue evaluada mediante el análisis de la varianza promedio extraída (AVE). Un valor de AVE de 0.50 o superior indica que el constructo explica, en promedio, más de la mitad de la varianza de sus indicadores, lo que satisface los requisitos de validez convergente. Los valores presentados en la Tabla 1 confirman que este criterio se cumple.

Por otro lado, la validez discriminante o divergente, se emplea para comprobar si los constructos o variables latentes del modelo, son conceptualmente distintos entre sí. Para verificar este criterio de validez en el modelo de medición, se utilizó el método propuesto por Hair et al. (2017), basado en el criterio de Fornell-Larcker. Este enfoque compara la raíz cuadrada de los valores de AVE con las correlaciones entre las variables latentes. En particular, la raíz cuadrada del AVE de cada constructo debe ser mayor que su correlación más elevada con cualquier otro constructo, lo que implica que un constructo comparte más varianza con sus propios indicadores que con otros constructos. Los resultados evidenciaron que en este modelo se cumple con el criterio de Validez Divergente.

Modelo Estructural

Según Hair et al., (2017), el modelo estructural, es una representación conceptual que ilustra las relaciones entre los constructos o variables latentes. La forma más habitual para




Figura 2. Modelo Estructural Analizado

representarlo, es a través de un diagrama que muestra las relaciones entre las variables latentes o constructos. En este modelo, la Utilidad Percibida y la Confirmación de las Expectativas actúan como variables independientes. Por otra parte, la Satisfacción y la Intención de Uso de IA Generativa para el aprendizaje autónomo, se configura como la variable dependiente. La Figura 2 muestra el modelo estructural que fue probado utilizando el software SmartPLS.

El análisis del modelo estructural permitió analizar las hipótesis y comprobarlas parcialmente. En primer lugar, la hipótesis H1 no fue aceptada, ya que la relación entre la utilidad percibida y la intención de continuar utilizando herramientas de inteligencia artificial generativa para el aprendizaje autónomo no resultó estadísticamente significativa (0.072 ; $p\text{-valor} > 0.05$). Por otra parte, el análisis lleva a aceptar la hipótesis H2 ya que la relación obtenida, fue positiva y significativa entre la utilidad percibida y la satisfacción (0.455 ; $p\text{-valor} < 0.05$), lo cual indica que una mayor percepción de utilidad incrementa el nivel de satisfacción del usuario. Asimismo, la hipótesis H3 también fue confirmada, mostrando que la confirmación de expectativas influye de manera positiva y significativa en la satisfacción (0.443 , $p\text{-valor} < 0.05$). Finalmente, la hipótesis H4 fue ampliamente respaldada, con una fuerte y significativa relación entre la satisfacción y la intención de uso de IA (0.804 , $p\text{-valor} < 0.05$). Este resultado sugiere además que la satisfacción, puede actuar como un mediador clave en la intención de continuar utilizando estas herramientas. Estos hallazgos, refuerzan la importancia de la experiencia de uso y la percepción de cumplimiento de expectativas como determinantes en la aceptación de la inteligencia artificial en contextos educativos y principalmente el hecho de que, estas variables, tienen una influencia importante para el uso de IA en el aprendizaje autónomo de estudiantes universitarios.

Discusión de Resultados

Los hallazgos obtenidos en esta investigación aportan evidencia empírica significativa sobre el impacto de la inteligencia artificial (IA) en el fortalecimiento del aprendizaje autónomo en estudiantes universitarios, en el marco del modelo de Expectativa-Confirmación (ECM). Un análisis general evidencia que las hipótesis planteadas y corroboradas parcialmente, destacan

el papel mediador de la satisfacción en la intención de uso continuo de herramientas de IA, subrayando, además, la relevancia de la experiencia de uso y la confirmación de expectativas. El hecho de que no se haya aceptado la hipótesis H1, referida a la influencia directa de la utilidad percibida sobre la intención de uso continuo de herramientas de IA generativa para el aprendizaje autónomo, resulta un hallazgo relevante, ya que contradice en parte lo planteado por autores como Zhu et al. (2021) y Pan et al. (2024), quienes señalaron que la percepción de utilidad se relaciona directamente con la disposición del estudiante a seguir empleando tecnologías educativas. Esta divergencia puede explicarse por la mediación que ejerce la variable satisfacción, como se intuye de la comprobación de la hipótesis H4, donde se evidencia que la utilidad percibida, si bien no influye directamente en la intención de uso de IA generativa, lo hace indirectamente al aumentar la satisfacción del estudiante. Este hallazgo fortalece la intención de continuidad, y corrobora señalado por Baharum et al. (2021) y Wang y Li (2024), quienes argumentan que la satisfacción es un factor clave en la adopción sostenida de tecnologías digitales, particularmente en entornos educativos mediados por IA.

La confirmación de expectativas también resultó ser un determinante significativo de la satisfacción (H3), lo que corrobora lo obtenido por Baharum et al. (2021) y Wang y Wang (2019), quienes evidenciaron que la percepción positiva del desempeño de una tecnología, cuando se alinea con las expectativas iniciales, genera un efecto favorable que incrementa la satisfacción del usuario. En el presente estudio, los estudiantes que percibieron que las herramientas de IA cumplieron o superaron sus expectativas, reportaron mayores niveles de satisfacción, lo cual refuerza la idea de que las primeras experiencias de uso son determinantes para configurar actitudes positivas hacia la tecnología.

Los resultados de la hipótesis H2, demuestran que la utilidad percibida influye significativamente en la satisfacción, lo cual está alineado con lo encontrado en estudios previos como los de Zhou & Zhang (2024) y Gutiérrez-Castillo et al. (2025), quienes destacan que los estudiantes experimentan mayores niveles de satisfacción cuando las herramientas tecnológicas les permiten planificar, monitorear y regular su propio aprendizaje. Esta asociación sugiere que los estudiantes no solo valoran la funcionalidad de

la IA, sino también su capacidad para apoyar procesos metacognitivos vinculados al aprendizaje autónomo.

El resultado de la comprobación de la hipótesis H4, evidencia que la satisfacción es el predictor más robusto de la intención de continuar utilizando IA para el aprendizaje autónomo. Este hallazgo se alinea con lo reportado por Pan et al. (2024) y Quinde et al. (2024), quienes argumentan que los estudiantes tienden a mantener el uso de tecnologías digitales en la medida en que estas generan experiencias positivas y significativas en su proceso formativo. Este resultado también corrobora lo expuesto por Feng et al. (2023), quienes identificaron que las trayectorias de aprendizaje personalizadas y efectivas, impulsadas por IA, fortalecen la disposición de los estudiantes a integrar permanentemente estas tecnologías en su rutina académica.

Los resultados también se pueden contrastar con los hallazgos obtenidos por Gotavade (2024) y Wu et al. (2024), quienes destacaron que, si bien la IA ofrece un potencial considerable para transformar la educación, su efectividad depende en gran medida del contexto de implementación, del acompañamiento docente y de la alfabetización digital de los estudiantes. En ese sentido, los resultados obtenidos respaldan parcialmente estas afirmaciones, ya que, aunque se observa un alto grado de aceptación de la IA cuando esta cumple con las expectativas y se percibe como una tecnología útil, también se identifica que la experiencia positiva debe estar mediada por una satisfacción subjetiva que impulse su uso sostenido.

Implicancias

Respecto a las implicancias prácticas del presente estudio, los hallazgos realizan un aporte al conocimiento científico, al permitir corroborar lo planteado en el Modelo de Expectativa-Confirmación (ECM) en contextos educativos mediados por inteligencia artificial, validando su aplicabilidad en el análisis del aprendizaje autónomo en educación superior. La evidencia empírica obtenida, refuerza el rol central de la satisfacción como posible variable mediadora, entre la utilidad percibida, la confirmación de expectativas y la intención de uso continuo, tal como lo habían anticipado trabajos previos en otros contextos tecnológicos (Oliver, 1980; Baharum et al., 2021; Pan et al., 2024). No obstante, este estudio aporta una novedosa contribución al extender el ECM, específicamente al ámbito del aprendizaje autónomo

asistido por IA, lo que permite vincular conceptos tradicionalmente analizados por separado, dentro de un marco teórico integrador. Además, se destaca que la utilidad percibida no influye de forma directa en la intención de uso, como lo proponen los modelos clásicos, lo que sugiere la necesidad de repensar las relaciones directas en los marcos teóricos existentes y considerar modelos más complejos con efectos mediadores y contextuales.

Desde un enfoque práctico, los resultados permiten a docentes y autoridades universitarias, tomar decisiones informadas respecto a la adopción e integración de herramientas basadas en inteligencia artificial generativa. Se demuestra que la satisfacción del estudiante es un factor determinante para garantizar la continuidad del uso de estas tecnologías, lo que implica que su implementación no debe limitarse a la dimensión funcional o instrumental. Por tanto, es fundamental que las herramientas de IA generativa respondan efectivamente a las expectativas iniciales de los estudiantes, ofreciendo retroalimentación oportuna, personalización en las trayectorias de aprendizaje, y soporte en procesos de autorregulación. Asimismo, se recomienda incluir instancias de acompañamiento docente y formación en alfabetización digital, que permitan a los estudiantes desarrollar competencias para utilizar estas tecnologías de manera autónoma, con pensamiento crítico y de forma ética.

Conclusiones

Esta investigación evidenció que la integración de herramientas de inteligencia artificial generativa puede contribuir significativamente al fortalecimiento del aprendizaje autónomo en contextos universitarios, siempre que se cumplan las expectativas iniciales del estudiante y se genere una experiencia satisfactoria de uso. A través del modelo ECM, se demostró que la confirmación de expectativas y la satisfacción son factores clave que influyen en la intención de continuar utilizando tecnologías de IA para apoyar el proceso formativo. Si bien la utilidad percibida no mostró una influencia directa en la intención de uso, su efecto indirecto a través de la satisfacción sugiere un rol más complejo que debe ser considerado por los modelos teóricos actuales. Estos hallazgos destacan la importancia de diseñar entornos de aprendizaje inteligentes centrados en el estudiante, que no solo incorporen tecnología, sino que también promuevan experiencias significativas, personalizadas y emocionalmente positivas, como base para una educación superior más autónoma, inclusiva y sostenible.



Limitaciones y Futuras Investigaciones

Este estudio presentó algunas limitaciones que es necesario destacar. Entre las principales se encuentra el uso de un diseño transversal, que impide establecer relaciones causales entre las variables analizadas. Asimismo, la muestra estuvo compuesta únicamente por estudiantes de una universidad ecuatoriana, lo que podría limitar en alguna medida la generalización de los hallazgos a otros contextos educativos o culturales. Aunque se aplicó un cuestionario validado y adaptado culturalmente, la naturaleza autoinformada del instrumento puede haber influido en las respuestas por sesgo de deseabilidad social.

A partir de las limitaciones señaladas, se sugiere que futuras investigaciones adopten diseños longitudinales que permitan observar cómo evolucionan las percepciones de utilidad, satisfacción e intención de uso a lo largo del tiempo. También sería relevante replicar el estudio en otras instituciones de educación superior, tanto a nivel nacional como internacional. Asimismo, se propone incorporar análisis cualitativos complementarios, a través de diseños fenomenológicos o estudios de caso, con el propósito de explorar en mayor profundidad las experiencias subjetivas de los estudiantes con herramientas de IA.

Referencias

- AL-Tkhayneh, K. M., Alghazo, E. M., & Tahat, D. (2023). The advantages and disadvantages of using artificial intelligence in education. *Journal of Educational and Social Research*, 13(4), 105. <https://doi.org/10.36941/jesr-2023-0094>
- Avramenko, A., & Bulanova, E. (2024). Prospects for the development of student self-study in the context of integrating artificial intelligence technologies into foreign language education. *Rhema*. <https://doi.org/10.31862/2500-2953-2024-1-79-91>
- Bao, H. (2024). Learning evaluation method based on artificial intelligence technology and its application in education. *Journal of Electrical Systems*, 20(3s), 1833-1842. <https://doi.org/10.52783/jes.1722>
- Baharum, A., Fai, C., Ismail, R., Ismail, I., Deris, F., & Noor, N. (2021). Evaluation of appliances mobile controller system using expectation-confirmation theory model. *Bulletin of Electrical Engineering and Informatics*, 10(4), 2119-2129. <https://doi.org/10.11591/eei.v10i4.3061>



- Blancas Sánchez, J., Camborda Zamudio, M., Quispe López, C., & Coaquira Rojo, C. A. (2024). Gamified and artificial intelligence-assisted knowledge base in a social platform for self-learning in higher education. 2024 International Symposium on Accreditation of Engineering and Computing Education (ICACIT), 1–6.
<https://doi.org/10.1109/ICACIT62963.2024.10788662>
- Dhia, A. W. and Kholid, M. N. (2021). Explaining e-wallet continuance intention: a modified expectation confirmation model. Jurnal Minds: Manajemen Ide Dan Inspirasi, 8(2), 287. <https://doi.org/10.24252/minds.v8i2.23592>
- Feng, M., Zhang, Q., & Yan, J. (2023). Exploring the effectiveness of individualized learning trajectories in university smart sports education classrooms: a design and implementation study. Journal of Social Science Humanities and Literature, 6(5), 67-73. [https://doi.org/10.53469/jsshl.2023.06\(05\).10](https://doi.org/10.53469/jsshl.2023.06(05).10)
- Gotavade, T. S. (2024). Artificial intelligence ecosystem for automating self-directed teaching. arXiv. <https://doi.org/10.48550/arXiv.2411.07300>
- Gutiérrez-Castillo, J. J., Tena, R. R., & León-Garrido, A. (2025). Beneficios de la Inteligencia Artificial en el aprendizaje de los estudiantes universitarios: una revisión sistemática. Edutec, Revista Electrónica De Tecnología Educativa, (91), 185-206.
- Hair Jr, J. F., Matthews, L. M., Matthews, R. L., & Sarstedt, M. (2017). PLS-SEM or CB-SEM: updated guidelines on which method to use. International Journal of Multivariate Data Analysis, 1(2), 107-123
- Han, B. (2019). Application of artificial intelligence in autonomous english learning among college students. International Journal of Emerging Technologies in Learning (Ijet), 14(06), 63. <https://doi.org/10.3991/ijet.v14i06.10157>
- Kline, R. B. (2023). *Principles and practice of structural equation modeling*. Guilford publications.
- Макаренко, О., Borysenko, O., Horokhivska, T., Kozub, V., & Yaremenko, D. (2024). Embracing artificial intelligence in education: shaping the learning path for future professionals. Multidisciplinary Science Journal, 6, 2024ss0720.
<https://doi.org/10.31893/multiscience.2024ss0720>
- Oliver, R. L. (1980). A cognitive model of the antecedents and consequences of satisfaction decisions. Journal of marketing research, 17(4), 460-469.
- Pan, G., Mao, Y., Song, Z., & Nie, H. (2024). Research on the influencing factors of adult learners' intent to use online education platforms based on expectation confirmation theory. Scientific Reports, 14(1). <https://doi.org/10.1038/s41598-024-63747-9>



- Quinde, G. A. L., Muñoz, M. Y. T., Suárez, J. M. R., Villarreal, R. E. P., Vélez, W. A. Z., & Laínez, A. A. D. P. (2024). Perception of university students on the use of artificial intelligence (ai) tools for the development of autonomous learning. *Revista De Gestão Social E Ambiental*, 18(2), e06170. <https://doi.org/10.24857/rgsa.v18n2-136>
- Salas-Pilco, S. Z. and Yang, Y. (2022). Artificial intelligence applications in latin american higher education: a systematic review. *International Journal of Educational Technology in Higher Education*, 19(1). <https://doi.org/10.1186/s41239-022-00326-w>
- Wang, L., & Li, W. (2024). The impact of AI usage on university students' willingness for autonomous learning. *Behavioral Sciences*, 14(10), 956. <https://doi.org/10.3390/bs14100956>
- Wang, M. and Wang, J. (2019). Understanding solvers' continuance intention in crowdsourcing contest platform: an extension of expectation-confirmation model. *Journal of Theoretical and Applied Electronic Commerce Research*, 14(3), 17-33. <https://doi.org/10.4067/s0718-18762019000300103>
- Wu, D., Zhang, S., Ma, Z., Yue, X. G., & Dong, R. K. (2024). Unlocking potential: Key factors shaping undergraduate self-directed learning in AI-enhanced educational environments. *Systems*, 12(9), 32. <https://doi.org/10.3390/systems12090332>
- Xia, Q., Chiu, T. K. F., & Chai, C. (2022). The moderating effects of gender and need satisfaction on self-regulated learning through artificial intelligence. *Education and Information Technologies*, 28, 8691–8713. <https://doi.org/10.1007/s10639-022-11547-x>
- Younas, M., El-Dakhs, D. A. S., & Jiang, Y. (2025). A comprehensive systematic review of AI-driven approaches to self-directed learning. *IEEE Access*, 13, 38387–38403. <https://doi.org/10.1109/ACCESS.2025.3546319>
- Zhou, J., & Zhang, H. (2024). Factors influencing university students' continuance intentions towards self-directed learning using artificial intelligence tools. *Applied Sciences*, 14(18), 8363. <https://doi.org/10.3390/app14188363>
- Zhu, T., Liu, B., Song, M., & Wu, J. (2021). Effects of service recovery expectation and recovery justice on customer citizenship behavior in the e-retailing context. *Frontiers in Psychology*, 12. <https://doi.org/10.3389/fpsyg.2021.658153>

Conflicto de intereses:

Los autores declaran que no existe conflicto de interés posible.

Financiamiento:

No existió asistencia financiera de partes externas al presente artículo.

Agradecimiento:

N/A