

ARTÍCULO

Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE)

Integrated Model of AI Adoption in Higher Education (IMAI4HE)

JUAN MEJÍA TREJO*, OMAR GUILLERMO ROJAS ALTAMIRANO**,
CÉSAR OMAR MORA PÉREZ*, JUAN PABLO PATIÑO KARAM**

*Universidad de Guadalajara

**Universidad Panamericana Campus Guadalajara

Correo electrónico: jmejia@cucea.udg.mx

Recibido el 25 de febrero del 2025; aprobado el 9 de marzo del 2026

RESUMEN

La integración de la IA en la educación superior requiere modelos comprensivos para potenciar las nuevas formas de aprendizaje centradas en el estudiante. Este artículo propone soluciones a través del Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE) para mejorar el proceso educativo. Los factores clave explorados en la adopción del IMAI4HE se basan en la conciencia de la importancia de la propia carrera, la innovación y la sostenibilidad.

Se recopilaron datos de 749 estudiantes universitarios mexicanos en 2024. Tres expertos integraron paneles Delphi y grupos focales, y diseñaron los factores IAM4HE para el cuestionario. Posteriormente, se aplicó el análisis PLS-SEM para determinar las relaciones subyacentes.

El modelo IMAI₄HE fue validado, mostrando principalmente relaciones entre conocimiento, motivación, confianza, preparación e intención de uso. Las recomendaciones prácticas incluyen reforzar el conocimiento para mejorar su relación con la preparación y aprovechar ambas relaciones: la motivación para confiar y la preparación para la intención de uso.

El modelo IMAI₄HE se fundamenta en expertos y usuarios multidisciplinarios, enfocado en la innovación y la sostenibilidad en el desarrollo profesional del estudiante y en la adopción de la IA en la educación superior. Las relaciones entre la motivación para confiar y la preparación para la intención de uso son los predictores más fuertes para una adopción sencilla de la IA en este modelo. Sin embargo, el conocimiento teórico por sí sólo aún no es suficiente. Entre las limitaciones se encuentra el uso de una muestra específica de México; por lo tanto, este estudio sigue siendo exploratorio, no confirmatorio.

PALABRAS CLAVE: Modelo integrado; Inteligencia artificial; Educación superior

ABSTRACT AI integration in higher education needs comprehensive frameworks to enhance the new forms of learning based on the student. This paper proposes solutions through the Integrated Model of AI Adoption in Higher Education (IMAI₄HE) to improve the education process. The key factors explored in IAMI₄HE adoption are based on awareness of the importance of one's career, innovation, and sustainability.

Data was collected from 749 Mexican university students in 2024. Three experts integrated Delphi panels and focus groups and designed the IAM₄HE factors for the questionnaire. After this, the PLS-SEM analysis was applied to determine the underlying relationships.

The IMAI₄HE framework was validated, showing mainly relationships between knowledge, motivation, trust, preparedness, and use intention. Practical recommendations include reinforcing knowledge to improve its relationship with preparedness and taking advantage of both relationships: motivation to trust and preparedness to use intention.

The IMAI₄HE framework is based on multidisciplinary experts and users, focused on innovation and sustainability in the student's career development and AI adoption in higher education.

The relationships between motivation to trust and preparedness to use intentions are the strongest predictors for easy AI adoption

in the IMAI4HE framework. However, theoretical knowledge alone is still not enough. Limitations include a Mexico-specific sample; hence, this study is still exploratory, not confirmatory.

KEYWORDS: Integrated model; Artificial intelligence; Higher education

INTRODUCCIÓN

La educación superior constituye un ámbito de especial relevancia para analizar la forma en que la inteligencia artificial (IA) interactuará con estudiantes en etapas iniciales de formación, representando una oportunidad sustantiva para transformar y mejorar los procesos educativos —en nuestro caso, el proceso de aprendizaje del estudiante de educación superior—. En este sentido, la interacción entre la IA y los estudiantes, orientada al fortalecimiento de su formación académica, exige la definición de nuevos modelos conceptuales capaces de afrontar desafíos estructurales, particularmente en economías emergentes como la de México. Asimismo, resulta indispensable considerar los esfuerzos globales que subrayan la importancia de la innovación en consonancia con los Objetivos de Desarrollo Sostenible (ODS) (UN, 2015), especialmente en lo relativo al desempeño profesional futuro.

Ambos factores evidencian una brecha en la comprensión de los elementos que influyen en la disposición del estudiantado de nivel pregrado y posgrado para adoptar la IA en contextos educativos.

El presente estudio introduce el Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), centrado en factores clave de carácter exploratorio tales como el conocimiento, la motivación, la confianza, la preparación y la intención de uso de la IA. La investigación tiene como propósito dilucidar la manera en que estos factores interactúan para propiciar una adopción exitosa de la IA en la educación superior, mediante la aplicación de métodos cualitativos y cuantitativos.

En consecuencia, se formula la siguiente pregunta de investigación: ¿De qué manera el conocimiento, la motivación, la confianza y la preparación influyen en la intención del estudiantado de utilizar la IA en la educación superior?

El estudio aporta hallazgos preliminares de alto valor para el diseño de estrategias futuras orientadas a optimizar la adopción de la IA en la educación superior, sustentadas en la concientización de las distintas disciplinas profesionales respecto a la promoción de la innovación y el desarrollo sostenible como objetivos educativos de alcance global.

CONTEXTO

En la actualidad, la inteligencia artificial (IA) experimenta un crecimiento acelerado en prácticamente todos los ámbitos del conocimiento y la actividad humana. En consecuencia, resulta imperativo diseñar modelos conceptuales y operativos robustos que orienten la incorporación de la IA en la educación superior, con un enfoque explícito en el fortalecimiento de las trayectorias profesionales, la promoción de la innovación y el impulso del desarrollo sostenible. Dichos modelos deben estructurarse de manera que garanticen el desarrollo del conocimiento, la motivación, la confianza y la preparación necesarias para el uso pertinente y estratégico de la IA con tales fines.

En este contexto, tanto la Organización para la Cooperación y el Desarrollo Económicos (OCDE, 2024) como la Oficina de Tecnología Educativa (OET, 2023) subrayan el papel crítico de la IA en la transformación de los ecosistemas educativos, destacando su potencial para reconfigurar procesos de enseñanza-aprendizaje, modelos institucionales y dinámicas de generación de conocimiento en la educación superior.

Contexto Mundial

En el contexto global, la inteligencia artificial (IA) está redefiniendo de manera estructural el conjunto de los procesos educativos, particularmente en los sistemas de educación superior, lo que evidencia la necesidad de fortalecer y reconfigurar la interacción entre el estudiantado y la IA. No obstante, persiste una carencia de modelos integrales suficientemente robustos que permitan potenciar, en la educación superior, el pleno aprovechamiento del potencial de la IA. La eficacia de estos modelos debe contemplar múltiples dimensiones orientadas al estudiantado, tales como la personalización de las experiencias de aprendizaje, el fortalecimiento de la accesibilidad y la preparación para economías impulsadas por la IA (OECD, 2024). Dada la relevancia de la innovación para el desarrollo sostenible, los modelos de IA en educación superior deben promover el desarrollo de capacidades críticas —como la resolución de problemas complejos, la adaptabilidad y la eficiencia tecnológica— con el propósito de preparar a los estudiantes para trayectorias profesionales en industrias caracterizadas por transformaciones aceleradas. Asimismo, dichos modelos deben evidenciar cómo la IA puede respaldar las iniciativas institucionales orientadas a la sostenibilidad, fomentando la investigación en ámbitos estratégicos como soluciones climáticas y energías renovables, y vinculando la educación con la responsabilidad ambiental (WEF, 2023).

Contexto de los Estados Unidos (EU)

El desarrollo de modelos de IA para la educación superior en EU constituye una prioridad nacional. La integración de la IA en los entornos académicos contribuye, por ejemplo, a mejorar las tasas de retención mediante estrategias de aprendizaje personalizado y a optimizar la eficiencia administrativa (OET, 2023). En términos generales, el diseño de modelos de IA debe incorporar directrices claras para el uso responsable de la tecnología, garantizar la equidad en el acceso digital y fortalecer la protección de datos personales, asegurando que las aplicaciones de IA cumplan con estándares éticos elevados. Asimismo, estos modelos permiten a las instituciones educativas fomentar la innovación mediante el análisis de tendencias en las necesidades del mercado laboral, alineando los planes de estudio con los sectores emergentes de empleo. El informe de la OET destaca además la necesidad de integrar de manera explícita los principios de sostenibilidad dentro de los modelos de IA, promoviendo la articulación entre inteligencia artificial, ciencias ambientales y desarrollo profesional (OET, 2023).

Contexto de México

En México, los modelos de IA adquieren una relevancia creciente tanto para la atención de problemáticas socioeconómicas como para la promoción de la innovación, particularmente en el ámbito educativo, en alineación con los objetivos nacionales de desarrollo. Se observan avances significativos en las políticas de IA en el país (OECD, 2024), especialmente en instituciones de educación superior como el Tecnológico de Monterrey (ITESM) y la Universidad Nacional Autónoma de México (UNAM). Ambas instituciones han desarrollado modelos y estrategias para aprovechar la IA en la generación de trayectorias formativas flexibles, la ampliación del acceso educativo en zonas rurales y la articulación de programas académicos con las demandas del mercado laboral. No obstante, los modelos de IA en México continúan en proceso de evolución y requieren incorporar de manera más explícita el enfoque de sostenibilidad para enfrentar desafíos críticos en áreas como la eficiencia energética, la planificación urbana y la gestión hídrica. La integración estratégica de la IA en la educación superior ofrece a las universidades la oportunidad de posicionar a sus egresados como líderes en desarrollo sostenible, fortaleciendo su inserción en sectores de alta demanda como el análisis de datos, la ética de la IA y la investigación climática (OECD, 2024).

REVISIÓN DE LA LITERATURA

La inteligencia artificial (IA) se está consolidando como un factor central en la evolución de la educación superior, influyendo en las metodologías educativas y, en consecuencia, en el compromiso del estudiantado. En este sentido, la presente sección tiene como propósito abordar de manera sintética cómo la innovación, la sostenibilidad y la preparación profesional se articulan con el conocimiento, la motivación, la confianza, la preparación y la intención de uso del estudiantado, en la configuración de sistemas de educación superior impulsados por IA. Asimismo, se presenta literatura clave para explorar y analizar estos factores dentro del diseño Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI_{4HE}. Integrated Model of AI Adoption in Higher Education),.

La innovación como eje central en la educación superior para alcanzar la sostenibilidad

El Oslo Manual (OECD, 2018) permite a las instituciones educativas y universidades orientar la formación académica hacia múltiples tipos de innovación, incluyendo innovación de producto, de servicios, de marketing, de procesos, organizacional, empresarial y social, además de la innovación tecnológica. La sostenibilidad (OECD, 2024b), en sus tres dimensiones fundamentales —ambiental, social y económica— puede alinearse con los modelos de IA para contribuir al logro de los Objetivos de Desarrollo Sostenible (SDG) (UN, 2025).

Conocimiento: fundamento para la integración de la IA

El conocimiento constituye un determinante clave para la adopción exitosa de la IA en la educación superior. El estudiantado debe comprender las herramientas de IA y sus aplicaciones para aprovechar eficazmente sus beneficios (Delcker et al., 2024).

La alfabetización en IA debe abarcar la comprensión de la IA generativa tanto en sus capacidades como en sus limitaciones, lo cual resulta esencial para fomentar un uso informado y crítico (Al-Abdullatif, 2024).

Las instituciones educativas y universidades desempeñan un papel central cuando incorporan la formación en IA dentro de los planes de estudio, promoviendo una comprensión sistemática de su potencial para apoyar el aprendizaje personalizado y la resolución de problemas complejos (Crompton & Burke, 2023).

Motivación: motor del compromiso

La motivación influye significativamente en la disposición del estudiantado para adoptar la IA. Hmoud et al. (2024) destacan el papel de la motivación orientada a la tarea en entornos de aprendizaje potenciados por IA.

La IA generativa, como ChatGPT, puede fortalecer el compromiso estudiantil al proporcionar retroalimentación inmediata y recursos de aprendizaje adaptativos. Sin embargo, la motivación sostenida requiere la alineación de las herramientas de IA con las metas intrínsecas y extrínsecas del estudiantado, tales como el logro académico y la preparación profesional (Wang et al., 2023).

Confianza: construcción de credibilidad en los sistemas de IA

La confianza constituye un elemento fundamental para la adopción exitosa de la IA en la educación superior. Andreeva et al. (2024) proponen un “ecosistema de confianza” que integra confiabilidad, transparencia y consideraciones éticas dentro del diseño de modelos de IA en educación superior.

La IA resulta más atractiva y aceptada cuando el estudiantado la percibe como confiable y capaz de proteger la privacidad de sus datos (Vincent-Lancrin & van der Vlies, 2020; OECD, 2020). Entre las estrategias para fortalecer la confianza se incluyen la implementación de mecanismos de rendición de cuentas y la comunicación clara sobre las limitaciones de la IA (Milicevic et al., 2024).

Preparación: asegurando la disposición institucional y estudiantil

La disposición del estudiantado para adoptar e integrar la IA en sus rutinas académicas se refleja en la dimensión de preparación. Delcker et al. (2024) analizaron la competencia en IA de estudiantes de primer año, identificando su capacidad predictiva respecto al uso real y la intención de uso de tecnologías de IA.

La preparación se encuentra influida por la exposición previa a la IA, el apoyo institucional y el acceso a recursos de formación (Mah & Groß, 2024). En este sentido, las instituciones deben priorizar el desarrollo docente y la inversión en infraestructura para fomentar una cultura de preparación y adaptación tecnológica.

Intención de uso: predicción del comportamiento de adopción

La IA ejerce un impacto positivo en la intención del estudiantado de utilizarla. Milicevic et al. (2024) sostienen que la utilidad percibida respalda significativamente la intención de uso de la IA.

Resulta pertinente vincular este factor con modelos conductuales como el TAM (Technology Acceptance Model), lo que permite comprender de manera más profunda la interacción de variables en la adopción de tecnologías de IA. Asimismo, la personalización de soluciones de IA sensibles al contexto puede fortalecer la intención de uso al responder a las necesidades y preferencias específicas del estudiantado (Wang & Li, 2024).

Diseño del modelo conceptual

Esta sección describe los métodos cualitativos y cuantitativos aplicados preliminarmente en el diseño del Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education). El método cualitativo incluyó la aplicación de un Panel Delphi–Focus Group combinado con el Proceso Analítico Jerárquico (AHP, por sus siglas en inglés) (Saaty, 2008).

En este proceso participaron tres especialistas:

Un experto en tecnologías de la información (visión profesional).

Un profesor de tecnologías de la información (visión académica).

Un estudiante universitario (visión del usuario).

A partir de este procedimiento, se identificaron los indicadores considerados factores clave que constituyen el Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), como modelo conceptual, integrando las dimensiones de conocimiento, motivación, confianza, preparación e intención de uso.

Los especialistas también definieron los indicadores o preguntas dirigidas al estudiantado universitario, centradas en tres áreas fundamentales: desarrollo profesional, innovación y sostenibilidad. El cuestionario final se detalla en la Tabla 1.

El Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education) finalizado y determinado por los especialistas, es diseñado a partir de los criterios para el análisis multivariante y creación de escalas (Mejía-Trejo, 2017, 2018) e identifica seis conexiones clave esenciales para promover la integración efectiva de la IA en la educación superior.

Tabla 1. Fundamentación del modelo IMAL4HE mediante Delphi–Focus Group y AHP

Nombres sugeridos por 1 profesor de tecnologías de la información (visión académica) y 1 estudiante universitario (visión del usuario)		Prioridades sugeridas por 1 experto en tecnologías de la información (visión profesional)
Factores	Indicadores basados en la percepción (Escala Likert 1–7) (1 = Totalmente en desacuerdo; 2 = En desacuerdo; 3 = Algo en desacuerdo; 4 = Ni de acuerdo ni en desacuerdo; 5 = Algo de acuerdo; 6 = De acuerdo; 7 = Totalmente de acuerdo)	Prioridades AHP (%) Importancia
1. KNW (Conocimiento)	KNW1. Sé que la IA puede utilizarse para reconocer y buscar imágenes, voces y datos relacionados con mi carrera profesional.	47
	KNW2. Sé que la IA puede utilizarse para traducir, parafrasear y mejorar documentos innovadores relacionados con mi carrera profesional.	30
	KNW3. Sé que la IA puede utilizarse para crear documentos orientados a la sostenibilidad relacionados con mi carrera profesional.	23
	Total	100
2. MOT (Motivación)	MOT1. Estoy motivado(a) para aprender sobre IA debido a su aplicación en mi desarrollo profesional.	38
	MOT2. Estoy motivado(a) para aprender sobre IA por su utilidad en la generación de propuestas de desarrollo sostenible en mi carrera.	34
	MOT3. Estoy motivado(a) para aprender sobre IA porque contribuye a la generación de propuestas innovadoras en mi campo profesional.	28
	Total	100
3. TST (Confianza)	TST1. Confío en aprender y utilizar IA para desarrollar mi carrera profesional.	40
	TST2. Confío en aprender y utilizar IA para generar propuestas innovadoras en mi carrera.	35
	TST3. Confío en aprender y utilizar IA para generar propuestas de desarrollo sostenible en mi carrera.	25
	Total	100
4. PRP (Preparación)	PRP1. Me siento preparado(a) para utilizar tecnologías de IA en la resolución de problemas que surjan en mi ejercicio profesional.	40
	PRP2. Me siento preparado(a) para utilizar tecnologías de IA al proponer innovaciones en mi carrera.	38
	PRP3. Me siento preparado(a) para utilizar tecnologías de IA en la atención de problemáticas relacionadas con el desarrollo sostenible en mi campo profesional.	22
	Total	100
5. USI (Intención de uso)	USI1. Siempre que es posible, aprendo y utilizo IA para desarrollar mi carrera profesional.	45
	USI2. Siempre que es posible, aprendo y utilizo IA en el desarrollo de propuestas innovadoras en mi carrera.	33
	USI3. Siempre que es posible, aprendo y utilizo IA para desarrollar propuestas de desarrollo sostenible en mi área de estudio.	22
	Total	100

Notas: KNW: Conocimiento MOT: Motivación TST: Confianza; PRP: Preparación; USI: Intención de uso

Conocimiento del estudiante (KNW) → Preparación del estudiante (PRP)

El conocimiento (KNW) influye positivamente en la preparación (PRP); cuando los estudiantes poseen conocimientos suficientes, desarrollan mayores competencias para involucrarse y estar mejor preparados frente a las tecnologías de IA.

Los modelos de adopción de IA en educación superior han evidenciado una amplia investigación sobre cómo KNW y PRP influyen en la adopción efectiva de tecnologías de IA para el éxito en el aprendizaje. Delcker et al. (2024) subrayan que el uso de herramientas de IA por parte del estudiantado está significativamente determinado por las ventajas percibidas y las actitudes positivas hacia la IA. La integración de la alfabetización en IA en los procesos educativos permite un uso crítico y altamente efectivo de estas tecnologías, fortaleciendo el crecimiento académico y profesional, así como el desempeño en entornos de aprendizaje modernos.

Mah y Groß (2024) destacan que tanto docentes como estudiantes requieren mayor alfabetización en IA para maximizar beneficios como el aprendizaje personalizado y la equidad educativa. Asimismo, la falta de preparación en IA puede obstaculizar la adaptación a la transformación digital y limitar el aprovechamiento de la IA para el éxito académico y profesional (Mah & Groß, 2024). Este vínculo subraya la necesidad de integrar la educación en IA en los planes de estudio para preparar al estudiantado ante un entorno académico y profesional impulsado por IA (Crompton & Burke, 2023; Magrill & Magrill, 2024; Mejía-Trejo, 2025).

H1: “A mayor KNW, mayor PRP.”

Conocimiento del estudiante (KNW) → Confianza del estudiante (TST)

El conocimiento (KNW) influye positivamente en la confianza (TST). Una comprensión más profunda de las capacidades y limitaciones de la IA refuerza la percepción de confiabilidad. La interacción entre alfabetización en IA, KNW y TST es fundamental para la adopción de IA generativa en la educación superior. El conocimiento sobre IA fortalece la confianza en aspectos clave como seguridad, utilidad y fiabilidad, facilitando su integración en el proceso de aprendizaje (Al-Abdullatif, 2024; Mejía-Trejo, 2024). Andreeva et al. (2024) proponen un “ecosistema de confianza” que requiere comprensión, transparencia y adhesión a principios éticos en el diseño de IA. Vincent-Lancrin y van der Vlies (2020) sostienen que fomentar la confianza exige sistemas de IA explicables, transparentes y responsables. En consecuencia, el desarrollo de KNW fortalece TST, permitiendo una interacción ética y crítica con la IA.

H2: “A mayor KNW, mayor TST.”

Motivación del estudiante (MOT) → Confianza del estudiante (TST)

La motivación (MOT) influye positivamente en la confianza (TST). Los estudiantes motivados perciben la IA como una herramienta confiable. Chan & Hu (2023) señalan que los

estudiantes motivados adoptan la IA cuando la perciben útil, transparente y éticamente alineada. Wang et al. (2023) destacan que los entornos de apoyo y las creencias de expectativa-valor fortalecen la motivación, lo que incrementa la confianza en herramientas de IA. La motivación intrínseca favorece la adopción de herramientas basadas en IA mediante experiencias personalizadas (Mohamed et al., 2024).

H3: “A mayor MOT, mayor TST.”

Motivación del estudiante (MOT) → Preparación del estudiante (PRP)

La motivación (MOT) influye positivamente en la preparación (PRP). Wang & Li (2024) indican que la motivación intrínseca y la autoeficacia digital incrementan la disposición del estudiantado para interactuar con herramientas de IA. Hmoud et al. (2024) evidencian que herramientas interactivas como ChatGPT fortalecen la preparación para adoptar y utilizar eficazmente la IA. Asimismo, Crompton y Burke (2023) destacan que la alineación entre herramientas de IA y necesidades estudiantiles potencia el compromiso y la preparación.

H4: “A mayor MOT, mayor PRP.”

Confianza del estudiante (TST) → Preparación del estudiante (PRP)

La confianza (TST) influye positivamente en la preparación (PRP). Slimi (2023) señala que la confianza depende de la transparencia, beneficios demostrables y alineación ética. Percepciones positivas de herramientas como chatbots incrementan la disposición estudiantil (Schei et al., 2024).

No obstante, Zhai et al. (2024) advierten que una confianza excesiva puede sustituir el razonamiento independiente. Por ello, la transparencia y la ética son esenciales para fortalecer una preparación crítica.

H5: “A mayor TST, mayor PRP.”

Preparación del estudiante (PRP) → Intención de uso (USI)

Finalmente, la preparación (PRP) influye positivamente en la intención de uso (USI). Estudiantes mejor preparados tienden a adoptar la IA para mejorar su desempeño académico. Milicevic et al. (2024) destacan que la influencia social, la expectativa de desempeño y la expectativa de esfuerzo determinan la intención conductual de adopción. Asimismo, estudiantes preparados integran la IA como herramienta colaborativa, fortaleciendo procesos metacognitivos (Atchley et al., 2024). Una preparación adecuada reduce riesgos de dependencia cognitiva y favorece un uso productivo y reflexivo de la IA.

H6: “A mayor PRP, mayor USI.”

METODOLOGÍA

Esta sección describe el proceso de ensamblaje del diseño y la recolección de datos que fueron objeto de análisis, desarrollado en tres etapas:

Etapas 1. Se aplicó un Panel Delphi–Focus Group combinado con el Proceso Analítico Jerárquico (AHP), como estudio cualitativo, para el diseño *ex-ante* del cuestionario final del Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education). Participaron tres especialistas con visiones complementarias: un experto en tecnologías de la información (visión profesional), un profesor de tecnologías de la información (visión académica) y un estudiante universitario (visión del usuario). Estos especialistas intervinieron en la identificación de los determinantes que conforman el constructo conceptual del modelo IMAI4HE. Como resultado, se definieron cinco factores distribuidos en 15 ítems.

Etapas 2. Se realizó una revisión de la literatura para sustentar y delimitar los factores e indicadores incorporados en el diseño final del cuestionario del modelo IMAI4HE. El instrumento fue elaborado y aplicado en 2024 a una muestra de 749 estudiantes universitarios mexicanos.

Etapas 3. Se empleó el modelo PLS-SEM (Partial Least Squares Structural Equation Modeling), mediante Análisis Factorial Confirmatorio (CFA), como estudio cuantitativo, utilizando el software SmartPLS 4.1.0.9. El análisis CFA examinó tres tipos de validez del Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), convergente, discriminante y nomológica.

Datos demográficos

La muestra estuvo conformada por 749 participantes. Los principales resultados descriptivos, derivados del análisis de frecuencias, fueron los siguientes: edades entre 18 y 29 años (718; 95.9%), sexo masculino (387; 51.9%), estado civil soltero(a) (713; 95.6%), nivel de licenciatura (712; 95.6%) y procedencia de universidades públicas (493; 65.8%). Véase la Tabla 2.

Tabla 2. Perfil demográfico de la muestra

Medida	Categorías	Frecuencia	Porcentaje
Edad	18–29	718	95.9%
	30–39	17	2.3%
	40–49	6	0.8%
	50–59	8	1.1%
	Total	749	100%
Género	Masculino	387	51.9%
	Femenino	359	48.1%
	Total	746*	100%
Estado civil	Soltero(a)	713	95.6%
	Casado(a)	33	4.4%
	Total	746*	100%
Nivel educativo	Licenciatura	712	95.6%
	Maestría	28	3.8%
	Doctorado	5	0.7%
	Total	745*	100%
Tipo de institución educativa	Pública	493	65.8%
	Privada	256	34.2%
	Total	749	100%

Fuente: Elaboración propia

Determinación del tamaño de muestra con base en la técnica PLS-SEM

La adecuación del tamaño muestral fue determinada siguiendo las directrices metodológicas del enfoque Partial Least Squares Structural Equation Modeling (PLS-SEM) y mediante un análisis de potencia estadística (statistical power analysis), conforme a los criterios establecidos por Cohen (1988) y Hair et al. (2019). El modelo estructural del marco IMAI4HE presenta un máximo de tres predictores directos sobre un constructo endógeno (específicamente, la Preparación –PRP– es explicada por Conocimiento –KNW–, Motivación –MOT– y Confianza –TST–). En PLS-SEM, el tamaño de muestra requerido se determina considerando el mayor número de relaciones estructurales que inciden sobre un constructo endógeno.

Asumiendo:

un tamaño de efecto medio ($f^2 = 0.15$),

un nivel de significancia de $\alpha = 0.05$,

y una potencia estadística deseada de 0.80,

los criterios de Cohen (1988) indican que el tamaño mínimo de muestra requerido para un modelo con hasta tres predictores es aproximadamente **77 observaciones**. Incluso

bajo un supuesto conservador de tamaño de efecto pequeño ($f^2 = 0.02$), el tamaño mínimo estimado sería cercano a 395 observaciones.

La muestra final del estudio estuvo conformada por 749 estudiantes universitarios mexicanos, superando ampliamente los requisitos mínimos derivados del análisis de potencia estadística. Asimismo, este tamaño muestral excede el criterio complementario de la “regla de las 10 veces” recomendada en la literatura PLS-SEM (Hair et al., 2019), que sugiere que el tamaño de muestra debe ser al menos diez veces el mayor número de caminos estructurales que inciden sobre un constructo endógeno. En consecuencia, el tamaño de muestra utilizado garantiza:

- Estabilidad en la estimación de parámetros,
- Precisión en los coeficientes de trayectoria,
- Capacidad para detectar efectos pequeños y medianos, y
- Robustez en el contraste de hipótesis dentro del marco PLS-SEM.

Por tanto, el diseño muestral del presente estudio proporciona condiciones metodológicas sólidas para la validación del modelo estructural IMAI4HE.

Recolección de datos

La presente investigación empleó el método de “muestreo virtual en bola de nieve” para recopilar una muestra representativa de participantes. Se obtuvieron 749 respuestas con el propósito de capturar las percepciones del estudiantado a partir del cuestionario final presentado en la Tabla 1.

El instrumento fue distribuido mediante Google Forms entre el 6 de enero y el 6 de diciembre de 2024. La participación fue voluntaria, confidencial y sin incentivos. En consecuencia, la muestra —centrada en la relación entre inteligencia artificial, innovación, sostenibilidad y su relevancia para el desarrollo profesional, enmarcada en el Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), — refleja las perspectivas de estudiantes universitarios.

Instrumento de medición

El estudio utilizó la metodología Delphi Panel–Focus Group combinada con la técnica AHP (Analytic Hierarchy Process), con la participación de tres especialistas: un experto

en tecnologías de la información (perspectiva profesional), un profesor de tecnologías de la información (perspectiva académica) y un estudiante universitario (perspectiva de usuario). Estas aproximaciones se aplicaron dentro del modelo conceptual IMAI4HE.

En modalidad reflexiva, todos los factores fueron evaluados a partir de la siguiente pregunta en escala Likert:

“¿Cómo percibe los siguientes aspectos en una escala Likert del 1 al 7 (1 = Totalmente en desacuerdo; 2 = En desacuerdo; 3 = Algo en desacuerdo; 4 = Ni de acuerdo ni en desacuerdo; 5 = Algo de acuerdo; 6 = De acuerdo; 7 = Totalmente de acuerdo)?”

Los resultados fueron analizados en tres rondas, emparejando a los especialistas en combinaciones únicas sin repetición; es decir, tres participantes organizados en dos combinaciones distintas (CombCal, 2023).

Mediante la técnica AHP, las rondas fueron ponderadas con base en las sugerencias del profesor de tecnologías de la información (perspectiva académica) y del estudiante universitario (perspectiva de usuario), mientras que el experto en tecnologías de la información (perspectiva profesional) estableció las prioridades que condujeron al desarrollo del cuestionario final compuesto por cinco factores y 15 ítems (véase Tabla 1).

El cuestionario final fue sometido a validación mediante Análisis Factorial Confirmatorio (CFA) con base en PLS-SEM (Partial Least Squares Structural Equation Modeling), utilizando el software SmartPLS 4.1.0.9. Se evaluaron la validez convergente, discriminante y nomológica, con el fin de garantizar que el instrumento midiera con precisión los constructos propuestos.

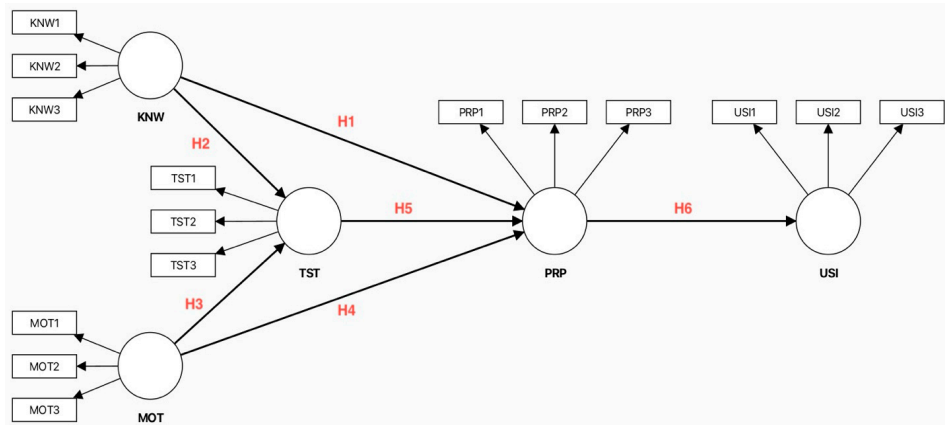
RESULTADOS

Los resultados se fundamentan en el análisis CFA mediante PLS-SEM, empleando el software SmartPLS 4.1.0.9 para la evaluación de la validez convergente, discriminante y nomológica de los cinco factores y sus 15 ítems.

Análisis factorial confirmatorio (CFA)

El Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), con sus factores e indicadores derivados del cuestionario final (ex-ante), se presenta en la Figura 1.

Figura 1. El modelo IMAI4HE como modelo ex-ante.



Notas: KNW: Conocimiento MOT: Motivación TST: Confianza; PRP: Preparación; USI: Intención de uso

Técnica de análisis CFA/PLS-SEM

El método PLS-SEM se orienta a maximizar la varianza explicada del modelo. Se fundamenta en dos componentes principales:

- Modelo de medición (modelo externo): tiene como finalidad definir las relaciones entre los factores latentes y las variables observadas.
- Modelo estructural (modelo interno): describe las asociaciones entre los factores latentes.

El procedimiento se basa en un algoritmo iterativo que alterna la estimación de los factores latentes a través de los modelos de medición y estructural hasta alcanzar la convergencia, momento en el cual el modelo SEM queda resuelto.

El modelo de medición estima las variables latentes como una combinación ponderada de sus indicadores observados, mediante regresión lineal simple o múltiple (Henseler et al., 2014; Dijkstra & Henseler, 2015; Rigdon et al., 2017).

Modelo de medición IMAI4HE

El software SmartPLS 4.0.9.6 fue utilizado para estimar el modelo de medición. Los resultados correspondientes se presentan en la Tabla 3.

Tabla 3. Resultados del modelo de medición IMAI4HE

Factor 1	Indicators	1.KNW. Cronbach's Alpha (≥ 0.7)= 0.890; rho_a (Composite Reliability) ≥ 0.7)= 0.892; rho_c (Dijkstra-Henseler's ≥ 0.7)= 0.932; Average Variance Extracted (AVE ≥ 0.5)=0.820	Outer loading (t-Value)	p Value
KNW	KNW1	Sé que la IA puede utilizarse para reconocer y buscar imágenes, voces y datos relacionados con mi carrera.	64.422	0.000
	KNW2	Sé que la IA puede utilizarse para traducir, parafrasear y mejorar documentos innovadores relacionados con mi carrera.	113.835	0.000
	KNW3	Sé que la IA puede utilizarse para crear documentos orientados a la sostenibilidad relacionados con mi carrera.	70.899	0.000
Factor 2	Items	2.MOT. Cronbach's Alpha (≥ 0.7)= 0.927; rho_a (Composite Reliability) ≥ 0.7)= 0.927; rho_c (Dijkstra-Henseler's ≥ 0.7)= 0.954; Average Variance Extracted (AVE ≥ 0.5)=0.873	Outer loading (t-Value)	p Value
MOT	MOT1	Estoy motivado(a) para aprender sobre IA debido a su aplicación en mi desarrollo profesional.	105.366	0.000
	MOT2	Estoy motivado(a) para aprender sobre IA por su uso en la generación de propuestas de desarrollo sostenible en mi carrera.	155.057	0.000
	MOT3	Estoy motivado(a) para aprender sobre IA porque genera propuestas de desarrollo sostenible en mi carrera.	111.085	0.000
Factor 3	Items	3.TST. Cronbach's Alpha (≥ 0.7)= 0.938; rho_a (Composite Reliability) ≥ 0.7)= 0.939; rho_c (Dijkstra-Henseler's ≥ 0.7)= 0.961; Average Variance Extracted (AVE ≥ 0.5)=0.890	Outer loading (t-Value)	p Value
TST	TST1	Confío en aprender y utilizar la IA para desarrollar mi carrera.	138.800	0.000
	TST2	Confío en aprender y utilizar la IA para generar propuestas innovadoras en mi carrera.	183.687	0.000
	TST3	Confío en aprender y utilizar la IA para generar propuestas de desarrollo sostenible en mi carrera.	129.658	0.000
Factor 4	Items	4.PRP. Cronbach's Alpha (≥ 0.7)= 0.942; rho_a (Composite Reliability) ≥ 0.7)= 0.943; rho_c (Dijkstra-Henseler's ≥ 0.7)= 0.963; Average Variance Extracted (AVE ≥ 0.5)=0.897	Outer loading (t-Value)	p Value
PRP	PRP1	Me siento preparado(a) para utilizar tecnología de IA para resolver los problemas que surjan en mi carrera.	115.260	0.000
	PRP2	Me siento preparado(a) para utilizar tecnología de IA al proponer innovaciones en mi carrera.	225.362	0.000
	PRP3	Me siento preparado(a) para utilizar tecnología de IA para abordar problemáticas vinculadas al desarrollo sostenible en mi carrera.	124.634	0.000
Factor 5	Items	5.USI. Cronbach's Alpha (≥ 0.7)= 0.942; rho_a (Composite Reliability) ≥ 0.7)= 0.942; rho_c (Dijkstra-Henseler's ≥ 0.7)= 0.963; Average Variance Extracted (AVE ≥ 0.5)=0.897	Outer loading	p Value
USI	USI1	Siempre que sea posible, aprendo y utilizo la IA para desarrollar mi carrera.	140.306	0.000
	USI2	Siempre que sea posible, aprendo y utilizo la IA en el desarrollo de propuestas de innovación en mi carrera.	156.80	0.000
	USI3	Siempre que sea posible, aprendo y utilizo la IA para desarrollar propuestas de desarrollo sostenible en mi campo de estudio.	134.750	0.000

Notas:

- KNW. Conocimiento; MOT. Motivación; TST. Confianza; PRP. Preparación; USI. Intención de uso
- Escala Likert 1-7: (1 = Totalmente en desacuerdo; 2 = En desacuerdo; 3 = Algo en desacuerdo; 4 = Ni de acuerdo ni en desacuerdo; 5 = Algo de acuerdo; 6 = De acuerdo; 7 = Totalmente de acuerdo).

- Las **cargas externas** de los indicadores deben ser > 0.70 ; valores entre $0.40-0.70$ pueden considerarse para eliminación únicamente si su supresión incrementa la fiabilidad compuesta por encima del umbral sugerido (Hair et al., 2023).
- **ρ_a** : Índice de fiabilidad compuesta (≥ 0.7).
- **ρ_c** : En investigación exploratoria, valores entre $0.6-0.7$ son aceptables; valores entre $0.7-0.9$ reflejan resultados satisfactorios a buenos (Hair et al., 2019).
- **AVE (Average Variance Extracted ≥ 0.5)**: Indica que más del 50% de la varianza del constructo es explicada por sus indicadores (Fornell & Larcker, 1981).

Fuente: Elaboración propia utilizando SmartPLS 4.1.0.9.

En consecuencia, el Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), cumple con los criterios establecidos para el modelo de medición.

Validez discriminante del IMAI4HE

Para el cálculo de la validez discriminante se utilizó el software SmartPLS versión 4.1.0.9.

Los resultados correspondientes se presentan en la Tabla 4.

Tabla 4. Validez discriminante del modelo de medición IMAI4HE

	Fornell & Larcker Criteria (Diagonal= Root Square -AVE) & HTMT Criteria Ratio $\leq 0.85 \leq 0.90$ for discriminant validity				
	KNW	MOT	PRP	TST	USI
KNW	0.905	0.640	0.423	0.585	0.422
MOT	0.582	0.934	0.589	0.808	0.635
PRP	0.387	0.551	0.947	0.661	0.718
TST	0.535	0.754	0.622	0.944	0.696
USI	0.387	0.593	0.677	0.654	0.947

Notas

- KNW. Conocimiento MOT. Motivación; TST. Confianza; PRP. Preparación; USI. Intención de uso
- La validez discriminante se calcula y representa mediante una matriz que incorpora los resultados de los criterios Heterotrait–Monotrait (HTMT) y Fornell & Larcker (Hair, 2023; Fornell & Larcker, 1981).
- HTMT: Los distintos constructos deben captar conceptos diferentes. Cuando los constructos presentan similitud conceptual, el valor de corte es 0.90 ; un valor de corte de 0.85 es considerado más conservador (Henseler et al., 2015).

Fuente: Elaboración propia utilizando SmartPLS 4.1.0.9.

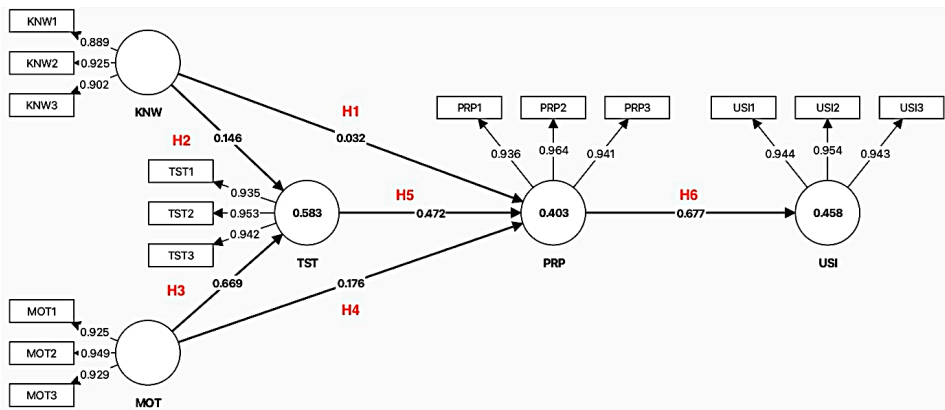
En consecuencia, el Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), cumple con los criterios de validez discriminante.

El modelo estructural

Los resultados de los coeficientes de trayectoria representan las relaciones hipotetizadas entre los constructos, estandarizadas en una escala de -1 a 1. Valores cercanos a -1 o 1 indican relaciones fuertes, mientras que valores próximos a 0 reflejan asociaciones débiles. En el procedimiento de *bootstrapping*, la significancia de estos coeficientes se determina mediante los valores *p* y los tamaños del efecto *f*. Este enfoque genera una distribución muestral aproximada a la normal, produciendo valores críticos *t* (Hair et al., 2019) y permitiendo evaluar la significancia práctica mediante valores *p* (Kraemer et al., 2003). La magnitud del efecto observado y su adecuación para influir en las conclusiones de investigación se analizan a través de la evaluación de la significancia práctica. Es importante establecer que relaciones estadísticamente significativas no siempre implican relevancia práctica. Asimismo, coeficientes de trayectoria pequeños pueden resultar estadísticamente significativos, por lo que su interpretación requiere cautela al formular conclusiones.

En este sentido, el juicio experto desempeña un papel fundamental en la evaluación, dado que no existe consenso sobre la medición de la significancia práctica (Kraemer et al., 2003). Finalmente, las relaciones del modelo estructural se validan con base en las hipótesis presentadas en la Figura 2.

Figura 2. El modelo conceptual IMAI4HE como modelo ex-post.



Notas:

- KNW. Conocimiento; MOT. Motivación; TST. Confianza; PRP. Preparación; USI. Intención de uso

Fuente: Elaboración propia usando SmartPLS 4.1.0.9

Poder explicativo del modelo IMAI4HE

El valor de R^2 (coeficiente de determinación) mide el poder explicativo del modelo a través de la proporción de varianza explicada en cada constructo endógeno.

Por ejemplo, de acuerdo con la Figura 2, el factor Confianza (TST) ($R^2 = 0.583$) indica que el 58.3% de su varianza es explicado por la variación conjunta de los constructos que inciden sobre él, considerando el criterio de R^2 ajustado en función del tamaño del modelo (James et al., 2013).

Asimismo, se emplea el tamaño del efecto f^2 , basado en tres umbrales para su evaluación (Cohen, 1988), específicamente para estimar la contribución de los factores exógenos subyacentes.

Véase la Tabla 5.

Tabla 5. Modelo estructural de medición IMAI4HE, pruebas de hipótesis y tamaño del efecto.

Hipótesis	Paths	*Path [t-value; p-value]	Resultado	*Intervalo		f ² Tamaño del efecto	
				2.5%-97.5% Confianza	Cruza o?	(0.02<=; 0.15 <=0.35)	Effect (Pequeño; Medio; Grande)
H1: «A mayor KNW, mayor PRP».	KNW -> PRP	0.032 [0.743; 0.229]	Rechazado	[-0.039; 0.105]	Sí	0.001	Pequeño
H2: «A mayor KNW, mayor TST».	KNW -> TST	0.146 [4.048; 0.000]	Acceptado	[0.085; 0.204]	No	0.034	Medio
H3: «A mayor MOT, mayor TST».	MOT -> TST	0.669 [20.863; 0.000]	Acceptado	[0.615; 0.721]	No	0.710	Grande
H4: «A mayor MOT, mayor PRP».	MOT ->PRP	0.176 [3.073; 0.001]	Acceptado	[0.082; 0.274]	No	0.020	Pequeño
H5: «A mayor TST, mayor PRP».	TST -> PRP	0.472 [9.040; 0.000]	Acceptado	[0.383; 0.554]	No	0.156	Medio
H6: «A mayor PRP, mayor USI».	PRP -> USI	0.677 [26.264; 0.000]	Acceptado	[0.632; 0.717]	No	0.845	Grande

Notas:

- En el modo bootstrapping, el símbolo * indica el resultado de la trayectoria con valores t unilaterales y valores p (entre paréntesis), calculados mediante el método percentil completo (más conservador), con un intervalo de confianza del 2.5%-97.5% (basado en n = 5000 submuestras) y un nivel de significancia de 0.05.
- f²: Tamaño del efecto con los siguientes umbrales (Cohen, 1988): 0.02 (pequeño), 0.15 (mediano) y 0.35 (grande).
- R²: Coeficiente de determinación. Valores de 0.25 (débil), 0.50 (moderado) y 0.75 (sustancial) (Hair et al., 2019).

Fuente: Elaboración propia utilizando SmartPLS 4.1.0.9.

En consecuencia, se concluye que el Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), funciona únicamente como un análisis de carácter exploratorio.

DISCUSIÓN

El Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), fue diseñado para examinar la interacción compleja de los factores que influyen en la adopción de la inteligencia artificial entre estudiantes. Integra el conocimiento del estudiante (KNW), la motivación (MOT), la confianza (TST), la preparación (PRP) y la intención de uso (USI) en un modelo robusto. La IA en la educación superior desempeña un papel transformador, y este modelo constituye una herramienta valiosa para comprender y fortalecer el proceso de adopción estudiantil. Investigaciones previas han explorado estas dimensiones de manera independiente. Por ejemplo:

Conocimiento en IA (KNW): Delcker et al. (2024) y Mah y Groß (2024) señalan que la alfabetización en IA fomenta la confianza; sin embargo, el conocimiento por sí sólo no garantiza necesariamente la preparación.

Motivación (MOT): Estudios como los de Chan & Hu (2023) y Wang et al. (2023) destacan que la motivación estudiantil es un impulsor determinante de la adopción de IA, influyendo tanto en la confianza como en la preparación.

Confianza (TST): Vincent-Lancrin y van der Vlies (2020) y Slimi (2023) subrayan que la confianza en la IA depende de valores como la transparencia, la ética y los beneficios demostrados. La confianza impacta significativamente la aceptación de los sistemas de IA por parte del estudiantado.

Preparación (PRP): Milicevic et al. (2024) afirman que la preparación actúa como un puente entre la conciencia sobre la IA y su adopción efectiva, influyendo directamente en la intención de uso.

El Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), propone cómo estas variables interactúan y contribuyen conjuntamente a la adopción de la IA en la educación superior, consolidando los hallazgos previos en un modelo teórico integrado. Los resultados presentados en la Tabla 5 aportan evidencia empírica sobre la validez del modelo e identifican áreas de mejora.

RESULTADOS DE HIPÓTESIS

H1: Mayor KNW → Mayor PRP (Rechazada)

El conocimiento no predice significativamente la preparación ($p = 0.229$, $f^2 = 0.001$). Este hallazgo cuestiona investigaciones previas (Delcker et al., 2024) que enfatizaban el conocimiento como fundamento de la preparación. Si bien el conocimiento incrementa la conciencia sobre la IA, no necesariamente se traduce en preparación sin experiencias prácticas.

Por ello, las instituciones deben complementar la adquisición de conocimientos en IA con experiencias de aprendizaje aplicado, como laboratorios de IA, proyectos prácticos y simulaciones.

H2: Mayor KNW → Mayor TST (Aceptada)

El conocimiento presenta un impacto significativo y de magnitud media sobre la confianza ($p < 0.000$, $f^2 = 0.034$), respaldando los hallazgos de Vincent-Lancrin y van der Vlies (2020). Cuando el estudiantado comprende el funcionamiento, las limitaciones y las implicaciones éticas de la IA, aumenta su percepción de confiabilidad y equidad.

Se recomienda desarrollar programas integrales de alfabetización en IA que incluyan transparencia, ética y aplicaciones reales.

H3: Mayor MOT → Mayor TST (Aceptada)

La motivación predice fuertemente la confianza ($p < 0.000$, $f^2 = 0.710$), lo que indica que estudiantes motivados perciben la IA como una herramienta alineada con sus metas. Chan & Hu (2023) demostraron que la motivación intrínseca, como la curiosidad y el compromiso académico, fortalece la confianza en sistemas de IA. Los docentes deben diseñar aplicaciones de IA orientadas a metas, incorporando casos reales y experiencias de éxito.

H4: Mayor MOT → Mayor PRP (Aceptada)

La motivación tiene un impacto estadísticamente significativo y de magnitud media en la preparación ($p = 0.001$, $f^2 = 0.020$), en concordancia con Wang & Li (2024). Aunque el tamaño del efecto es pequeño, la motivación favorece la disposición necesaria para adoptar la IA. Las instituciones deben fomentar la motivación mediante desafíos basados en IA, aprendizaje gamificado y proyectos alineados con trayectorias profesionales.

H5: Mayor TST → Mayor PRP (Aceptada)

La confianza presenta un impacto significativo y de magnitud media en la preparación ($p < 0.000$, $f^2 = 0.156$), confirmando lo señalado por Schei et al. (2024). Cuando los

estudiantes perciben la IA como ética, confiable y transparente, se sienten más preparados para interactuar con estas tecnologías. Las universidades deben garantizar que las herramientas de IA sean explicables, transparentes y alineadas con estándares éticos.

H6: Mayor PRP → Mayor USI (Aceptada)

La preparación es un predictor muy fuerte de la intención de uso ($p < 0.000$, $f^2 = 0.845$), en línea con Milicevic et al. (2024). Los estudiantes que se perciben preparados consideran la IA valiosa para su desempeño académico y profesional.

Las instituciones deben fortalecer programas integrales de preparación en IA que combinen formación teórica, aplicación práctica y apoyo institucional para facilitar una transición efectiva hacia su uso.

En conjunto, los hallazgos confirman que la motivación, la confianza y la preparación desempeñan roles determinantes en la adopción de la IA, mientras que el conocimiento, aunque necesario, requiere complementarse con experiencias prácticas para generar una preparación efectiva.

Implicaciones teóricas

El Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), propone un modelo integrado novedoso para explicar la adopción de la inteligencia artificial en la educación superior, validando relaciones clave entre conocimiento (KNW), motivación (MOT), confianza (TST), preparación (PRP) e intención de uso (USI). Los hallazgos destacan lo siguiente:

1. La confianza como mediadora: La confianza (TST) impulsa significativamente la preparación (PRP), reforzando su papel como habilitador crítico de la adopción de IA (Schei et al., 2024).
2. La motivación como impulsor central: La motivación (MOT) impacta positivamente tanto en la confianza (TST) como en la preparación (PRP), en consonancia con estudios previos (Chan & Hu, 2023; Wang & Li, 2024).
3. Brecha conocimiento–preparación: Si bien el conocimiento (KNW) mejora la confianza, no se traduce directamente en preparación, lo que cuestiona los supuestos de Delcker et al. (2024). Este resultado subraya la necesidad de incorporar aprendizaje experiencial.
4. El modelo representa un avance en las teorías de aceptación tecnológica al integrar dimensiones motivacionales y de confianza, ofreciendo una comprensión holística de los factores que influyen en la adopción de la IA en el ámbito educativo.

Implicaciones prácticas

Para fortalecer los resultados del Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), las instituciones educativas y universidades deberían centrarse en:

1. Alfabetización en IA para fortalecer la confianza: Incorporar transparencia, prácticas éticas y explicabilidad de la IA en los planes de estudio para fomentar la confianza (Vincent-Lancrin & van der Vlies, 2020).
2. Aprendizaje impulsado por la motivación: Implementar aprendizaje gamificado, proyectos de IA alineados con trayectorias profesionales y estudios de caso reales para estimular la motivación y la preparación (Chan & Hu, 2023).
3. Formación experiencial en IA: Combinar aprendizaje teórico con experiencias prácticas (p. ej., laboratorios de IA y simulaciones) para cerrar la brecha entre conocimiento y preparación.
4. Estrategias centradas en la confianza: Garantizar que las herramientas de IA sean confiables, éticas y transparentes para reducir incertidumbres y fortalecer la preparación.
5. Alineación con los ODS: Promover proyectos estudiantiles que utilicen IA para el desarrollo sostenible mediante soluciones innovadoras (Milicevic et al., 2024).

Al abordar estas áreas, el Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), ofrece estrategias accionables para preparar al estudiantado para la adopción de la IA, al tiempo que amplía la comprensión teórica sobre la aceptación tecnológica en la educación superior.

CONCLUSIONES

El Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), ha demostrado los roles interconectados del conocimiento (KNW), la motivación (MOT), la confianza (TST), la preparación (PRP) y la intención de uso (USI) en la promoción de la adopción de la IA en la educación superior.

Hallazgos de investigación

La pregunta de investigación —¿Cómo influyen el conocimiento, la motivación, la confianza y la preparación en la intención de uso de la IA en la educación superior?— se

responde a partir de los resultados obtenidos, los cuales evidencian relaciones significativas y matizadas entre los constructos analizados:

- Conocimiento y confianza (H2): El conocimiento influyó significativamente en la confianza ($f^2 = 0.034$), demostrando que comprender la funcionalidad, ética y limitaciones de la IA fortalece la percepción de confiabilidad y transparencia (Vincent-Lancrin & van der Vlies, 2020). La alfabetización en IA es esencial para consolidar la confianza estudiantil.
- Motivación y confianza (H3): La motivación emergió como un impulsor clave de la confianza ($f^2 = 0.710$). Las metas intrínsecas y la curiosidad incrementan la confianza en herramientas de IA, en concordancia con Chan & Hu (2023).
- Motivación y preparación (H4): La motivación impactó positivamente en la preparación ($f^2 = 0.020$), lo que indica que estudiantes motivados desarrollan mayor proactividad en la adquisición de competencias en IA (Wang & Li, 2024). No obstante, el tamaño del efecto reducido sugiere la necesidad de intervenciones complementarias.
- Confianza y preparación (H5): La confianza impactó significativamente en la preparación ($f^2 = 0.156$), reforzando el papel de sistemas de IA éticos, transparentes y confiables en la construcción de la disposición estudiantil (Schei et al., 2024).
- Preparación e intención de uso (H6): La preparación fue un predictor sólido de la intención de uso ($f^2 = 0.845$), confirmando que estudiantes seguros y competentes son más propensos a adoptar la IA (Milicevic et al., 2024).

En contraste, el impacto limitado del conocimiento sobre la preparación (H1) evidencia que la comprensión teórica no es suficiente, resaltando la importancia del aprendizaje práctico y experiencial.

Limitaciones de la investigación

Este estudio reconoce diversas limitaciones que abren oportunidades para futuras investigaciones:

- Generalización de la muestra: La investigación se centró en estudiantes universitarios mexicanos, lo que puede limitar su aplicabilidad a otros contextos culturales y educativos.
- Diseño transversal: El estudio captura un momento específico en el tiempo; se requieren estudios longitudinales para evaluar la evolución del modelo IMA14HE.
- Factores contextuales: Variables como infraestructura tecnológica, compromiso docente y preparación institucional no fueron abordadas en profundidad.

Líneas futuras de investigación

El Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), puede fortalecerse mediante:

- Ampliación de indicadores: Incrementar el número de ítems por factor (al menos 5–7 adicionales).
- Investigación longitudinal: Analizar la evolución del modelo a medida que el estudiantado interactúa con herramientas de IA.
- Análisis intercultural: Validar el modelo en distintos países y contextos institucionales.
- Perspectiva docente: Examinar el papel del profesorado dentro del modelo IMAI4HE.
- Estrategias pedagógicas innovadoras: Explorar enfoques como aprendizaje gamificado, actividades basadas en proyectos y desafíos impulsados por IA.

Al abordar estas líneas de investigación, el Modelo Integrado de Adopción de la IA en la Educación Superior (IMAI4HE. Integrated Model of AI Adoption in Higher Education), consolidarse como un modelo de referencia para orientar estrategias de adopción de IA en la educación superior, combinando aportes teóricos y aplicaciones prácticas.

REFERENCIAS

- Andreeva, A., Serafimova, D., Dimitrova, D. (2024). An Ecosystem of Trust in Using Artificial Intelligence in Higher Education. *Proceedings of The IIER International Conference*, Tashkent, Uzbekistan, 08 th -09th April, 2024. https://worldresearchlibrary.org/up_proc/pdf/6694-17200701001-5.pdf?utm_source=chatgpt.com
- Al-Abdullatif, A.M. (2024). Modeling Teachers' Acceptance of Generative Artificial Intelligence Use in Higher Education: The Role of AI Literacy, Intelligent TPACK, and Perceived Trust. *Education Sciences 14* (1209). https://worldresearchlibrary.org/up_proc/pdf/6694-17200701001-5.pdf?utm_source=chatgpt.com
- Atchley, P., Pannell, H., Wofford, K., Hopkins, M., & Atchley, R. A. (2024). Human and AI collaboration in the higher education environment: Opportunities and concerns. *Cognitive Research: Principles and Implications*, 9(20). https://cognitiveresearchjournal.springeropen.com/articles/10.1186/s41235-024-00547-9?utm_source=chatgpt.com
- Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences*. Routledge. <https://www.utstat.toronto.edu/~brunner/oldclass/378f16/readings/CohenPower.pdf>
- Combination Calculator (CombCal, 2023). Section 7. Combinations of m elements taken from n to n. Retrieved Dec-2-2023, from: https://www.estadisticaparatodos.es/software/misjavascript/javascript_combinatorio2.html
- Crompton, H. and Burke, D. (2023). Artificial intelligence in higher education: the state of the field. *International Journal of*

- Educational Technology in Higher Education 20 (22), 1-22 <https://doi.org/10.1186/s41239-023-00392-8>
- Chan, C. K. Y., & Hu, W. (2023). Students' voices on generative AI: Perceptions, benefits, and challenges in higher education. *International Journal of Educational Technology in Higher Education*, 20(43) <https://doi.org/10.1186/s41239-023-00411-8>
- Delcker, J., Heil, J., Ifenthaler, D., Seufert, S., & Spirgi, L. (2024). First-year students AI-competence as a predictor for intended and de facto use of AI-tools for supporting learning processes in higher education. *International Journal of Educational Technology in Higher Education*, 21(18). <https://doi.org/10.1186/s41239-024-00452-7>
- Dijkstra, T.K., Henseler, J. (2015). Consistent and asymptotically normal PLS estimators for linear structural equations. *Computational Statistics & Data Analysis*. 81, 10–23. <https://www.sciencedirect.com/science/article/pii/S0167947314002126?via%3Dihub>
- Fornell, C.L., & Larcker, D. F. (1981). Evaluating structural equation models with unobservable variables and measurement error. *Journal of Marketing Research* 18(1), 39-50. <https://www.jstor.org/stable/3151312>
- Hair, J.F.Jr., Sarstedt, M., Hopkins, L., Kuppelwieser, V.G. (2014). Partial least squares structural equation modeling (PLS-SEM): An emerging tool in business research, *European Business Review*, 26 (2), 106-121. <https://doi.org/10.1108/EBR-10-2013-0128>
- Hair, J.F., Babin, B.J., Anderson, R.E., Black, W.C. (2019). *Multivariate Data Analysis. 8th Edition*. Cengage. <https://www.amazon.com/Multivariate-Analysis-Joseph-Anderson-William/dp/9353501350>
- Hair, J.F., Sarstedt, M., Ringle, C.M., & Gudergan, S.P. (2023). Advanced issues in partial least squares structural equation modeling. Sage. <https://us.sagepub.com/en-us/nam/advanced-issues-in-partial-least-squares-structural-equation-modeling/book279526>
- Henseler, J., Dijkstra, T. K., Sarstedt, M.; Ringle, Ch. M.; Diamantopoulos, A.; Straub, D.W.; Ketchen, D. J.; Hair, J. F.; Hult, G. T. M. (2014). Common Beliefs and Reality About PLS. *Organizational Research Methods*. 17 (2), 182–209. <https://journals.sagepub.com/doi/10.1177/1094428114526928>
- Henseler, J., Ringle, C. M., & Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science* 43, 115–135. <https://link.springer.com/article/10.1007/s11747-014-0403-8>
- Hmoud, M., Swaity, H., Hamad, N., Karram, O., & Daher, W. (2024). Higher education students' task motivation in the generative artificial intelligence context: The case of ChatGPT. *Information*, 15(1), 33. https://www.mdpi.com/2078-2489/15/1/33?utm_source=chatgpt.com
- James, G. Witten, D., Hastie, T., and Tibshirani, R. (2013). An introduction to statistical learning. Springer. <https://link.springer.com/book/10.1007/978-1-4614-7138-7>
- Kraemer H.C. , Morgan, G.A., Leech, N.L., Gliner, J.A., Vaske, & Harmon, R.J. (2003). Measures of clinical significance. *Journal of the American Academy of Child & Adolescent Psychiatry* 42 (12), 1524–1529. [https://www.jaacap.org/article/S0890-8567\(09\)62138-9/fulltext](https://www.jaacap.org/article/S0890-8567(09)62138-9/fulltext)
- Magrill, J., & Magrill, B. (2024). Preparing educators and students at higher education institutions for an AI-driven world. *Teaching & Learning Inquiry*, 12. https://files.eric.ed.gov/fulltext/EJ1429106.pdf?utm_source=chatgpt.com

- Mah, D.-K., & Groß, N. (2024). Artificial intelligence in higher education: Exploring faculty use, self-efficacy, distinct profiles, and professional development needs. *International Journal of Educational Technology in Higher Education*, 21(58). <https://doi.org/10.1186/s41239-024-00490-1>
- Mejía-Trejo (2017). *Las ciencias de la administración y el análisis multivariante: Proyectos de investigación, análisis y discusión de los resultados Tomo II Las técnicas interdependientes*. CUCEA-UdeG. AMIDI.Biblioteca. <https://www.amidibiblioteca.amidi.mx/index.php/AB/catalog/book/21>
- Mejía-Trejo (2018). *Creación de Escalas en las Ciencia de la Administración*. CUCEA-UdeG. AMIDI.Biblioteca. <https://www.amidibiblioteca.amidi.mx/index.php/AB/catalog/book/18>
- Mejía-Trejo, J. (2024). *Inteligencia Artificial. Fundamentos de Ingeniería de Prompts con ChatGPT como Innovación Impulsora de la Creatividad (Más de 500 prompts incluidos)*. AMIDI. Biblioteca. <https://www.amidibiblioteca.amidi.mx/index.php/AB/catalog/book/48>
- Mejía-Trejo, J. (2025). *Inteligencia Artificial y su repercusión en la Educación Superior*. CUCEA-UdeG-AMIDI. En proceso de impresión. ISBN: 978-607-581-461-2
- Milicevic, N., Kalas, B., Djokic, N., Malcic, B., & Djokic, I. (2024). Students' intention toward artificial intelligence in the context of digital transformation. *Sustainability*, 16(9), 3554 https://www.mdpi.com/2071-1050/16/9/3554?utm_source=chatgpt.com
- Mohamed, A. M., Shaaban, T. S., Bakry, S. H., Guillén-Gámez, F. D., & Strzelecki, A. (2024). Empowering the Faculty of Education students: Applying AI's potential for motivating and enhancing learning. *Innovative Higher Education*. <https://doi.org/10.1007/s10755-024-09747-z>
- Office of Educational Technology (OET, 2023). *Artificial Intelligence and the Future of Teaching and Learning Insights and Recommendations*. eved December-16-2024, from: https://www.ed.gov/sites/ed/files/documents/ai-report/ai-report.pdf?utm_source=chatgpt.com
- Organisation for Economic Co-operation and Development (OECD, 2018). Oslo Manual. Retrieved Dec-23-2024, from: https://www.oecd.org/en/publications/oslo-manual-2018_9789264304604-en.html
- Organisation for Economic Co-operation and Development (OECD, 2020). Trustworthy artificial intelligence (AI) in education. Promises and challenges. Retrieved Dec-16-2024, from: https://www.oecd.org/en/publications/trustworthy-artificial-intelligence-ai-in-education_a6c90fa9-en.html?utm_source=chatgpt.com
- Organisation for Economic Co-operation and Development (OECD, 2024). *AI in Mexico. OECD.AI Policy Observatory*. Retrieved Dec-16-2024, from: https://oecd.ai/en/dashboards/countries/Mexico?utm_source=chatgpt.com
- Organisation for Economic Co-operation and Development (OECD, 2024b). *Environment at a glance indicators*. Retrieved Dec-16-2024, from: https://www.oecd.org/en/publications/environment-at-a-glance-indicators_ac4b8b89-en/full-report.html
- Rigdon, E. E., Sarstedt, M., Ringle, M. (2017). On Comparing Results from CB-SEM and PLS-SEM: Five Perspectives and Five Recommendations. *Marketing ZFP*. 39 (3), 4–16. doi:10.15358/0344-1369-2017-3-4. <https://www.beck-elibrary.de/10.15358/0344-1369-2017-3/marketing-zfp-volume-39-2017-issue-3>
- Schei, O. M., Møgelvang, A., & Ludvigsen, K. (2024). Perceptions and use of AI chatbots among students in higher education: A scoping review of empirical studies. *Education Sciences*, 14(8), 922. https://www.mdpi.com/2227-7102/14/8/922?utm_source=chatgpt.com

- Slimi, Z. (2023). *The impact of artificial intelligence on higher education: An empirical study*. *European Journal of Educational Sciences*, 10(1). <https://files.eric.ed.gov/fulltext/EJ1384682.pdf>
- United Nations (UN, 2015). Sustainable development Goals. Retrieved Dec-2-2024, from: <https://sdgs.un.org/goals>
- Vincent-Lancrin, S., & van der Vlies, R. (2020). *Trustworthy artificial intelligence (AI) in education: Promises and challenges*. OECD Education Working Papers, No. 218. <https://doi.org/10.1787/a6c90fa9-en>
- Wang, F., King, R. B., Chai, C. S., & Zhou, Y. (2023). University students' intentions to learn artificial intelligence: The roles of supportive environments and expectancy-value beliefs. *International Journal of Educational Technology in Higher Education*, 20(51). <https://doi.org/10.1186/s41239-023-00417-2>
- Wang, L., & Li, W. (2024). The impact of AI usage on university students' willingness for autonomous learning. *Behavioral Sciences*, 14 (956). [https://doi.org/10.3390/bs14100956​;contentReference\[oaicite:0\]{index=0}](https://doi.org/10.3390/bs14100956​;contentReference[oaicite:0]{index=0})
- World Economic Forum (WEF, 2023). *The Future of Jobs Report*. Retrieved 22-Dec-2024, from: <https://www.weforum.org>
- Zhai, C., Wibowo, S., & Li, L. D. (2024). The effects of over-reliance on AI dialogue systems on students' cognitive abilities: A systematic review. *Smart Learning Environments*, 11(28). https://slejournal.springeropen.com/articles/10.1186/s40561-024-00316-7?utm_source=chatgpt.com

