




INTELIGENCIA ARTIFICIAL GENERATIVA EN LA EDUCACIÓN SUPERIOR

Análisis Empírico y Modelado Predictivo con Python

**Espinoza-Mina, Marcos Antonio
Colina-Vargas, Alejandra Mercedes**

Inteligencia artificial generativa en la educación superior: Análisis empírico y modelado predictivo con Python

Autor/es:

Espinoza-Mina, Marcos Antonio
Universidad Tecnológica ECOTEC

Colina-Vargas, Alejandra Mercedes
Universidad Tecnológica ECOTEC

Espinoza-Mina, M.A.
Colina-Vargas, A.M.

Inteligencia artificial generativa en la educación superior: Análisis empírico y modelado predictivo con Python

Editorial Grupo AEA, Ecuador, 2025

ISBN: 978-9942-651-95-2

Formato: 210 cm X 270 cm

126 págs.



Publicado por Editorial Grupo AEA

Ecuador, Santo Domingo, Vía Quinindé, Urb. Portón del Río.

Contacto: +593 983652447; +593 985244607

Email: info@editorialgrupo-aea.com

<https://www.editorialgrupo-aea.com/>

Director General:	<i>Prof. César Casanova Villalba.</i>
Editor en Jefe:	<i>Prof. Giovanni Herrera Enríquez</i>
Editora Académica:	<i>Prof. Maybelline Jaqueline Herrera Sánchez</i>
Supervisor de Producción:	<i>Prof. José Luis Vera</i>
Diseño:	<i>Tnlgo. Oscar J. Ramírez P.</i>
Consejo Editorial	<i>Editorial Grupo AEA</i>

Primera Edición, 2025

D.R. © 2025 por Autores y Editorial Grupo AEA Ecuador.

Cámara Ecuatoriana del Libro con registro editorial No 708

Disponible para su descarga gratuita en <https://www.editorialgrupo-aea.com/>

Los contenidos de este libro pueden ser descargados, reproducidos difundidos e impresos con fines de estudio, investigación y docencia o para su utilización en productos o servicios no comerciales, siempre que se reconozca adecuadamente a los autores como fuente y titulares de los derechos de propiedad intelectual, sin que ello implique en modo alguno que aprueban las opiniones, productos o servicios resultantes. En el caso de contenidos que indiquen expresamente que proceden de terceros, deberán dirigirse a la fuente original indicada para gestionar los permisos.

Título del libro:

Inteligencia artificial generativa en la educación superior: Análisis empírico y modelado predictivo con Python

© Espinoza Mina, Marcos Antonio & Colina Vargas, Alejandra Mercedes.

© Noviembre, 2025

Libro Digital, Primera Edición, 2025

Editado, Diseñado, Diagramado y Publicado por Comité Editorial del Grupo AEA, Santo Domingo de los Tsáchilas, Ecuador, 2025

ISBN: 978-9942-651-95-2



<https://doi.org/10.55813/egaea.l.143>

Como citar (APA 7ma Edición):

Espinoza-Mina, M.A., & Colina-Vargas, A.M. (2025). *Inteligencia artificial generativa en la educación superior: Análisis empírico y modelado predictivo con Python*. Editorial Grupo AEA. <https://doi.org/10.55813/egaea.l.143>

Cada uno de los textos de Editorial Grupo AEA han sido sometido a un proceso de evaluación por pares doble ciego externos (double-blindpaperreview) con base en la normativa del editorial.

Revisores:



Ing. García Peña Víctor René,
PhD.

Universidad Laica Eloy Alfaro de
Manabí – Ecuador



Ing. Ramos Secaira Francisco
Marcelo, Mgs.

Pontificia Universidad Católica del
Ecuador; Instituto Tecnológico
Superior Los Andes
Idrix Technology S.A – Ecuador



Los libros publicados por “**Editorial Grupo AEA**” cuentan con varias indexaciones y repositorios internacionales lo que respalda la calidad de las obras. Lo puede revisar en los siguientes apartados:



Editorial Grupo AEA

 <http://www.editorialgrupo-aea.com>

 Editorial Grupo AeA

 editorialgrupoea

 Editorial Grupo AEA

Aviso Legal:

La información presentada, así como el contenido, fotografías, gráficos, cuadros, tablas y referencias de este manuscrito es de exclusiva responsabilidad del/los autor/es y no necesariamente reflejan el pensamiento de la Editorial Grupo AEA.

Derechos de autor ©

Este documento se publica bajo los términos y condiciones de la licencia Creative Commons Reconocimiento-NoComercial-CompartirIgual 4.0 Internacional (CC BY-NC-SA 4.0).



El “copyright” y todos los derechos de propiedad intelectual y/o industrial sobre el contenido de esta edición son propiedad de la Editorial Grupo AEA y sus Autores. Se prohíbe rigurosamente, bajo las sanciones en las leyes, la producción o almacenamiento total y/o parcial de esta obra, ni su tratamiento informático de la presente publicación, incluyendo el diseño de la portada, así como la transmisión de la misma de ninguna forma o por cualquier medio, tanto si es electrónico, como químico, mecánico, óptico, de grabación o bien de fotocopia, sin la autorización de los titulares del copyright, salvo cuando se realice confines académicos o científicos y estrictamente no comerciales y gratuitos, debiendo citar en todo caso a la editorial. Las opiniones expresadas en los capítulos son responsabilidad de los autores.

RESEÑA DE AUTORES

**Espinoza-Mina, Marcos Antonio**

Universidad Tecnológica ECOTEC

mespinoza@ecotec.edu.ec<https://orcid.org/0000-0003-1530-7243>

Ingeniero en Sistemas Computacionales, Magister en Negocios Internacionales y Comercio Exterior, Magister en Sistemas de Información, Magister en Estadística Aplicada y Doctor en Administración de Empresas. Miembro de la Red de Investigación, de Conocimiento Hardware y Software Libre. Investigador Agregado 2, Secretaría de Educación Superior, Ciencia, Tecnología e Innovación. Perito del Consejo de la Judicatura en la especialidad de Ingeniería Informática o de Sistemas. Profesional multidisciplinario, con sólida formación en investigación, docencia, y liderazgo de proyectos, tanto en los ámbitos académicos como empresariales. Posee habilidades que abarcan la gestión de proyectos, las tecnologías de la información, la gestión empresarial y el análisis de datos. Ímpetu por el aprendizaje continuo y la adaptabilidad, le ha permitido destacar en diversos roles, y aplicar la experiencia para abordar desafíos, fomentando el crecimiento, tanto de los estudiantes como de las organizaciones donde ha colaborado.

**Colina-Vargas, Alejandra Mercedes**

Universidad Tecnológica ECOTEC

acolina@ecotec.edu.ec<https://orcid.org/0000-0003-1514-8852>

Ingeniera de Sistemas, Magister en Gerencia de Tecnologías de Información y Comunicación, Magister en Sistemas de Información Mención en Inteligencia de Negocios y Analítica de Datos Masivos y Doctora en Educación. Miembro de la Red de Investigación, de Conocimiento Hardware y Software Libre. Investigador Agregado 1, Secretaría de Educación Superior, Ciencia, Tecnología e Innovación. Perito del Consejo de la Judicatura en la especialidad de Ingeniería Informática o de Sistemas. Profesional con más de 20 años de experiencia, investigadora de alto nivel con habilidades y competencias para el diseño y gestión de proyectos de apropiación, desarrollo y aplicación de las Tecnologías de Información y Comunicación, hardware y software libre, y otras tecnologías de vanguardia, que contribuyan a los procesos de transformación social y educativa del país. Destacada en la elaboración de propuestas de analítica de datos soportadas con software específicos aplicados a instituciones de administración pública y privada.

Índice

Reseña de Autores.....	ix
Índice.....	xi
Índice de Tablas.....	xv
Índice de Figuras.....	xv
Introducción.....	xvii
Capítulo I: Planteamiento de la investigación	1
1.1. La disrupción de la IA Generativa en la Academia.....	3
1.2. Planteamiento del problema: Tensiones fundamentales.....	5
1.3. Propósito, objetivos y preguntas de investigación.....	7
1.4. Justificación y aportes del estudio.....	9
1.5. Estructura de la obra.....	11
Capítulo II: Conceptualizando la interacción Humano-IA en la educación.....	13
2.1. Fundamentación teórica y empírica.....	15
2.2. Deconstruyendo la IA.....	16
2.2.1. IA General (IAG) frente a IA Estrecha (Narrow AI).....	16
2.2.2. La IA Generativa y su arquitectura subyacente.....	17
2.3. Mapeo de la investigación empírica internacional.....	19
2.4. Marcos teóricos para modelar la interacción Humano-IA.....	21
2.4.1. El modelo de aceptación tecnológica (TAM) y sus limitaciones..	22
2.4.2. La alfabetización en IA como competencia crítica.....	23
2.4.3. Implicaciones para la psicología educativa y la pedagogía crítica.....	24
Capítulo III: Diseño metodológico y validación del instrumento.....	27
3.1. Enfoque metodológico general del estudio.....	29
3.1.1. Justificación del enfoque cuantitativo-descriptivo.....	29

3.1.2.	Diseño secuencial del estudio: piloto y aplicación definitiva.....	30
3.1.3.	Fundamentos teóricos y operativos del instrumento	30
3.2.	Diseño y estructura de la encuesta piloto	31
3.2.1.	Propósito de la fase piloto	31
3.2.2.	Características operativas del instrumento.....	32
3.2.3.	Organización temática del cuestionario piloto	32
3.2.4.	Evaluación de la calidad del instrumento por los participantes ...	33
3.3.	Análisis técnico de resultados del piloto	33
3.3.1.	Propósito metodológico y valor estratégico del piloto.....	34
3.3.2.	Evaluación cuantitativa de percepción del instrumento.....	34
3.3.3.	Análisis de confiabilidad interna (alfa de Cronbach).....	35
3.3.4.	Correlaciones entre los ítems evaluativos	36
3.3.5.	Comportamiento de ítems y sesgos de respuesta	36
3.3.6.	Inconsistencias internas y reformulación de escalas.....	36
3.3.7.	Codificación temática del contenido abierto	37
3.3.8.	Evaluación estructural del cuestionario	37
3.4.	Rediseño del instrumento	37
3.4.1.	Consideraciones iniciales para el rediseño	38
3.4.2.	Consolidación y reorganización temática de bloques.....	38
3.4.3.	Reformulación de ítems y escalas de respuesta	39
3.4.4.	Incorporación de nuevos contenidos del análisis cualitativo	40
3.4.5.	Reducción estratégica de redundancias y extensión	40
3.4.6.	Optimización del entorno digital y navegabilidad.....	41
3.5.	Validación del instrumento definitivo.....	41
3.5.1.	Propósito y enfoque de la validación	41
3.5.2.	Análisis de confiabilidad interna	42
3.5.3.	Análisis de correlaciones coherencia interna	42

3.5.4.	Exploración preliminar de estructura factorial.....	43
3.5.5.	Validación de contenido y claridad interpretativa	44
3.5.6.	Conclusiones sobre la validación del instrumento.....	44
3.6.	Consideraciones finales y criterios éticos	44
3.6.1.	Reflexión metodológica integral.....	44
3.6.2.	Limitaciones técnicas y recomendaciones	45
3.6.3.	Consideraciones éticas en el diseño y aplicación del instrumento.....	45
3.6.4.	Conclusión sobre robustez metodológica.....	46
Capítulo IV:	Caracterización de la muestra de estudio	47
4.1.	Perfil del estudiante universitario en la era de la IA.....	49
4.2.	Perfil sociodemográfico de los participantes.....	50
4.2.1.	Composición por género.....	50
4.2.2.	Distribución etaria de la muestra	51
4.2.3.	Nivel académico de los encuestados	52
4.2.4.	Área de estudio de los participantes.....	53
4.3.	Perfil tecnológico: Interacción con la IA Generativa	54
4.3.1.	Ecosistema de herramientas: La hegemonía de ChatGPT	55
4.3.2.	Frecuencia de integración en la vida académica.....	55
4.4.	Síntesis del perfil del participante	56
Capítulo V:	Análisis de resultados y hallazgos estadísticos.....	59
5.1.	De los datos a las percepciones	61
5.2.	Análisis descriptivo de las percepciones estudiantiles por constructo	61
5.2.1.	Constructo de beneficios y utilidad percibida (P).....	62
5.2.2.	Constructo de riesgos y preocupaciones (C).....	63
5.2.3.	Constructo de actitud y postura institucional (A)	64
5.2.4.	Constructo de visión a futuro (F)	65

5.3.	Análisis inferencial: Explorando relaciones y diferencias	65
5.3.1.	Correlaciones entre las dimensiones de la percepción	65
5.3.2.	Análisis de diferencias entre grupos.....	67
5.4.	Tendencias dominantes e interpretación de los resultados.....	67
Capítulo VI: Aplicación de técnicas de Machine Learning.....		69
6.1.	De la descripción a la predicción y el descubrimiento de patrones	71
6.2.	Preparación del dataset para el modelado	72
6.3.	Modelos no supervisados: La segmentación de perfiles estudiantiles	73
6.3.1.	Determinación empírica del número óptimo de perfiles (K).....	73
6.3.2.	Caracterización e interpretación de los perfiles emergentes.....	74
6.3.3.	Visualización de la segmentación mediante PCA	75
6.4.	Modelos Supervisados: Predicción de la adopción de la IA	76
6.4.1.	Formulación del problema de clasificación.....	77
6.4.2.	Desarrollo y evaluación comparativa de los modelos.....	77
6.5.	Valor predictivo y aplicaciones institucionales estratégicas.....	79
Capítulo VII: Discusión e implicaciones de los hallazgos.....		81
7.1.	De los hallazgos a la interpretación	83
7.2.	Síntesis de un fenómeno complejo.....	84
7.3.	Diálogo con el marco teórico	85
7.4.	Navegando las contradicciones de la era de la IA.....	87
7.5.	Implicaciones para la política y la práctica educativa	89
Capítulo VIII: Conclusiones y futuras líneas de investigación.....		91
8.1.	Síntesis de los Principales Hallazgos	93
8.2.	Contribuciones de la investigación	94
8.3.	Recomendaciones estratégicas.....	94
8.4.	Limitaciones y futuras líneas de investigación.....	95
8.5.	La IA como fenómeno cultural y educativo	95

Referencias Bibliográficas	97
----------------------------------	----

Índice de Tablas

Tabla 1 Estadísticos descriptivos de la evaluación del instrumento piloto	35
Tabla 2 Análisis de confiabilidad de las subescalas del instrumento final	42
Tabla 3 Distribución de frecuencias y porcentajes por género	50
Tabla 4 Distribución de frecuencias y porcentajes por área de estudio	54
Tabla 5 Estadísticos descriptivos de las percepciones	62
Tabla 6 Perfiles de usuario según la respuesta promedio	74
Tabla 7 Métricas de rendimiento de los modelos de clasificación	77

Índice de Figuras

Figura 1 Distribución por género de los participantes	51
Figura 2 Distribución por rango de edad de los participantes	52
Figura 3 Distribución por año de estudio de los participantes	53
Figura 4 Distribución por área de estudio	54
Figura 5 Herramientas de IA Generativa más utilizadas	55
Figura 6 Frecuencia de uso de herramientas de IA Generativa	56
Figura 7 Valoración promedio por ítem en escala Likert (1-5)	62
Figura 8 Correlaciones de Pearson entre los constructos	66
Figura 9 Técnica del codo para la determinación de K óptimo	74
Figura 10 Visualización de los tres perfiles de usuario mediante PCA	76
Figura 11 Matriz de confusión para el modelo de Regresión Logística	78
Figura 12 Matriz de confusión para el clasificador de Árbol de Decisión	78
Figura 13 Matriz de confusión para el modelo Random Forest	79


Introducción

La irrupción de la inteligencia artificial (IA) generativa representa un hito tecnológico transformador de la era contemporánea, y su impacto en la educación superior ha sido inmediato y profundo. Herramientas como ChatGPT, Gemini o Copilot se han integrado en la vida académica a una velocidad sin precedentes, redefiniendo las prácticas de aprendizaje, enseñanza e investigación. Esta adopción masiva, liderada por el estudiantado, ha abierto un horizonte de posibilidades pedagógicas, pero también ha desatado desafíos éticos, metodológicos e institucionales.

Este libro, “Inteligencia Artificial Generativa en la Educación Superior: Análisis Empírico y Modelado Predictivo con Python”, nace de la necesidad de trascender el debate especulativo para ofrecer una comprensión rigurosa y basada en evidencia. A través de un estudio cuantitativo a gran escala, basado en una encuesta aplicada a 474 estudiantes universitarios, esta obra analiza las percepciones, patrones de uso y actitudes de la comunidad estudiantil. El análisis no se limita a describir dicha realidad, sino que avanza hacia su modelado.

Utilizando Python como herramienta central para el análisis estadístico y la aplicación de algoritmos de machine learning, este trabajo no solo caracteriza al estudiante usuario de IA, sino que también segmenta la población en perfiles actitudinales y desarrolla modelos que predicen la adopción a largo plazo de estas tecnologías. La investigación combina la validación psicométrica de un instrumento de medición con técnicas avanzadas de ciencia de datos, buscando ofrecer un análisis académicamente robusto y estratégicamente relevante.

Dirigido a investigadores, docentes, gestores educativos y profesionales de la tecnología, este libro es un recurso para comprender la interacción entre los estudiantes y la IA generativa. Su propósito es proporcionar datos y modelos para guiar el diseño de políticas institucionales y estrategias pedagógicas que permitan navegar esta nueva era con una visión informada, crítica y proactiva. En síntesis, esta obra ofrece una exploración analítica del núcleo de una de las revoluciones más significativas de la educación contemporánea.



CAPITULO 01

PLANTEAMIENTO DE LA INVESTIGACIÓN

Planteamiento de la investigación

1.1. La disrupción de la IA Generativa en la Academia

La historia de la educación superior es, en esencia, la historia de su adaptación a sucesivas revoluciones tecnológicas que han redefinido las fronteras del conocimiento y la pedagogía (Dabis & Csáki, 2024; Kim et al., 2025). Desde la imprenta de Gutenberg hasta la digitalización de las bibliotecas, cada hito ha reconfigurado las prácticas de enseñanza, aprendizaje e investigación (Baek et al., 2024).

Sin embargo, se puede argumentar que ninguna otra transformación tecnológica ha irrumpido en el ecosistema académico con la celeridad, la ubicuidad y la profundidad epistemológica que hoy definen a la IA generativa (Ursavaş et al., 2025). A diferencia de herramientas anteriores, su influencia no se limita a optimizar el acceso a la información, sino que interviene directamente en el proceso de creación del conocimiento mismo.

La presentación pública de modelos de lenguaje a gran escala (LLMs), con el lanzamiento de ChatGPT de OpenAI a finales de 2022 como catalizador principal, no representó simplemente la introducción de una nueva herramienta, sino el desencadenamiento de un cambio de paradigma (Baek et al., 2024; Qian, 2025). En un lapso de meses, lo que antes era dominio de laboratorios de investigación de vanguardia se materializó en interfaces intuitivas y accesibles, convirtiéndose en un componente funcional del día a día de millones de estudiantes y académicos en todo el planeta (Borges et al., 2024).

Esta irrupción no se ha limitado a un único actor tecnológico (Barus et al., 2025). El panorama ha madurado a una velocidad vertiginosa, consolidando un ecosistema competitivo en el que herramientas como Gemini de Google y Copilot de Microsoft, esta última integrada de manera nativa en el software de productividad más extendido del mundo, se han establecido como alternativas robustas (Gallent Torres et al., 2023; Nikolic, Sandison, et al., 2024). A ellas se suma una amplia gama de aplicaciones especializadas que adaptan las capacidades generativas a nichos específicos, desde la resolución de problemas

matemáticos hasta la creación de imágenes y la composición musical (Kanont et al., 2024).

Esta rápida diversificación y especialización ha cimentado a la IA generativa no como un fenómeno efímero, sino como una nueva infraestructura cognitiva global. Se ha convertido en una capa superpuesta a la internet, una especie de exo-córtex digital con el que la nueva generación de estudiantes interactúa de manera fluida para conceptualizar, explorar, sintetizar y producir conocimiento (Shi et al., 2025).

La capacidad de estos sistemas para generar texto con una coherencia y sofisticación sin precedentes, para depurar código, para traducir con fluidez, para resumir literatura académica densa y para operar en múltiples modalidades ha desdibujado, de facto, las fronteras de lo que tradicionalmente se ha considerado el trabajo intelectual humano (Đerić et al., 2025; Gasaymeh et al., 2024).

El momento histórico actual es, por consiguiente, singular, caracterizado por una adopción tecnológica masiva, acelerada y, crucialmente, bottom-up (Cabero-Almenara et al., 2025). A diferencia de innovaciones anteriores que a menudo fueron implementadas de manera centralizada por las instituciones (como los sistemas de gestión del aprendizaje o las bases de datos académicas), la IA generativa ha sido adoptada de manera orgánica y descentralizada por los propios usuarios (Barakat, 2025; Gallent Torres et al., 2023).

Los estudiantes, como miembros de una generación que ha socializado y aprendido en un entorno digital, no han esperado a recibir directrices institucionales para comenzar a experimentar. Han actuado como agentes autónomos, descubriendo casos de uso, desarrollando nuevas formas de interacción, lo que se conoce como prompt engineering, y forjando sus propias percepciones, a menudo complejas y ambivalentes, sobre la utilidad, las limitaciones y los peligros de esta nueva clase de tecnología (K. C. Li et al., 2025).

Este escenario de adopción viral y no mediada sitúa a las instituciones de educación superior ante una encrucijada ineludible. La cuestión ya no es si la IA generativa debe entrar en la universidad, sino cómo gestionar una realidad tecnológica que ya está profundamente imbricada en la vida intelectual de su

comunidad (Jensen et al., 2025). La inacción o la prohibición se revelan como estrategias insostenibles. Por lo tanto, el imperativo categórico para la academia contemporánea es investigar este fenómeno con rigor, profundidad y una visión de futuro que esté a la altura del desafío que representa (Chiu, 2024; Gallent Torres et al., 2023).

1.2. Planteamiento del problema: Tensiones fundamentales

La integración fáctica y generalizada de la IA generativa en el tejido de la vida universitaria ha cristalizado en un campo de profundas tensiones que interpelan los fundamentos mismos de la misión educativa (Oc et al., 2025). El problema central que articula la presente investigación es la asincronía crítica entre la velocidad exponencial de la adopción tecnológica por parte del estudiantado y la capacidad de respuesta, inherentemente más lenta y reflexiva, de las estructuras universitarias para desarrollar marcos pedagógicos, éticos y normativos que den sentido y dirección a esta transformación (Sallam et al., 2024). Esta brecha no es meramente un desfase temporal, sino un espacio de incertidumbre donde se dirimen cuestiones fundamentales sobre el futuro del aprendizaje, la evaluación y la integridad académica (Dabis & Csáki, 2024).

Desde una perspectiva pedagógica, la tensión se manifiesta en un dilema fundamental: ¿es la IA generativa una herramienta de andamiaje cognitivo que potencia el aprendizaje o una prótesis intelectual que lo atrofia? (Chen et al., 2025; Hong et al., 2025). Por un lado, su potencial para actuar como un tutor socrático personalizado, para simplificar conceptos complejos o para ayudar a los estudiantes a superar el bloqueo del escritor es innegable (C. Wu et al., 2024). Por otro, emerge una preocupación legítima de que una dependencia excesiva en estas herramientas pueda erosionar habilidades cognitivas de orden superior, como el pensamiento crítico, la capacidad de síntesis autónoma y el desarrollo de una voz autoral auténtica (Smit et al., 2025).

Este dilema impacta directamente en la evaluación del aprendizaje, que se enfrenta a una crisis de validez sin precedentes. Los métodos de evaluación tradicionales, basados en la producción de artefactos como ensayos o informes, se vuelven vulnerables (Fischer et al., 2024). Esto plantea preguntas críticas:

¿Cómo pueden los docentes discernir entre el trabajo original del estudiante y el texto generado por una máquina? (Kizilcec et al., 2024). ¿Qué nuevas formas de evaluación, quizás centradas en el proceso y no solo en el producto, son necesarias? (Chen et al., 2025). ¿Cómo se evalúa la competencia emergente de interactuar de manera crítica y eficaz con una IA? (Chiu, 2024). Estas preguntas no son meras cuestiones técnicas, sino que obligan a una profunda reinención de la cultura evaluativa (Kizilcec et al., 2024).

En el plano ético, las tensiones son, si cabe, aún más complejas (Gallent Torres et al., 2023). La noción tradicional de integridad académica se ve profundamente desafiada. La línea que separa el uso de la IA como un asistente de escritura legítimo (análogo a un editor gramatical avanzado o un colega que ofrece retroalimentación) y su uso como un sustituto del esfuerzo intelectual para cometer fraude académico es extraordinariamente difusa y depende del contexto (Gallent Torres et al., 2023; Kofinas et al., 2025). El concepto mismo de plagio, centrado en la apropiación de trabajo humano, requiere ser repensado en una era de contenido original pero no humano (Driessens & Pischetola, 2024).

A este dilema se suman preocupaciones igualmente graves sobre la privacidad de los datos, dado que los estudiantes a menudo introducen información personal, académica o incluso datos de investigación sensibles en plataformas comerciales cuyos modelos de negocio se basan en la recopilación de datos (L. Wang & Ren, 2024). El problema del sesgo algorítmico es también capital: los modelos de lenguaje, entrenados con vastos corpus de texto de internet, pueden reproducir y amplificar estereotipos y prejuicios sociales, presentando información sesgada como si fuera objetiva (Moore & Lookadoo, 2024).

En la dimensión tecnológica y social, la tensión se manifiesta en el riesgo de exacerbar las desigualdades existentes (Jin et al., 2025). El acceso diferencial a dispositivos de última generación, a conexiones a internet de alta velocidad o, de manera cada vez más relevante, a las versiones de suscripción (premium) de estas herramientas, que suelen ser más potentes, estar más actualizadas y ofrecer funcionalidades avanzadas, podría crear una nueva brecha digital entre los estudiantes (Borges et al., 2024; Gallent Torres et al., 2023). Esta inequidad no sería meramente de acceso, sino de capacidad, generando una estratificación

entre quienes pueden aprovechar todo el potencial de la IA y quienes solo pueden utilizar sus versiones más básicas (Baek et al., 2024).

En medio de este torbellino de debates teóricos, especulaciones y ansiedades, emerge un vacío crítico de conocimiento empírico (Chiu, 2024). Mientras abundan los editoriales y los ensayos de opinión, escasean los estudios a gran escala que revelen qué piensan, sienten y hacen realmente los estudiantes (Mourtajji & Arts-Chiss, 2024). La discusión pública y la formulación de políticas a menudo se basan en anécdotas, en extrapolaciones de grupos reducidos o en un pánico moral poco informado (Chiu, 2024; Singh & Ngai, 2024). Por tanto, el problema que esta investigación se propone resolver es la necesidad perentoria de generar una base de evidencia empírica, robusta y a gran escala sobre las percepciones, patrones de uso y actitudes del estudiantado (Kurtz et al., 2024). Solo a través de una comprensión profunda de la realidad vivida por los estudiantes será posible que el debate y las futuras políticas institucionales se fundamenten en datos y no en dogmas (Barus et al., 2025).

1.3. Propósito, objetivos y preguntas de investigación

Para abordar la problemática multidimensional descrita, la presente investigación se estructura en torno a un propósito central: analizar de manera sistemática y profunda la interacción del estudiantado universitario con las herramientas de IA generativa, con el fin último de generar conocimiento que sea a la vez académicamente riguroso y estratégicamente útil para la comunidad de educación superior (Abdaljaleel et al., 2024; Acosta-Enriquez et al., 2024). Este propósito general se desglosa en una serie de objetivos específicos que guían cada fase del estudio, los cuales, a su vez, se traducen en preguntas de investigación concretas que el análisis de datos buscará responder.

El objetivo general de esta obra es, por tanto, analizar las percepciones, los patrones de uso y las actitudes de los estudiantes universitarios hacia la IA generativa (Barus et al., 2025; Sousa & Cardoso, 2025). No se trata de una mera descripción, sino de un análisis que busca identificar relaciones, descubrir estructuras subyacentes y construir modelos predictivos (Acosta-Enriquez et al., 2024; Iulian et al., 2024). La finalidad es desarrollar una comprensión holística

del fenómeno que pueda servir de fundamento para la formulación de políticas institucionales, el diseño de estrategias pedagógicas innovadoras y la promoción de una cultura de uso de la IA que sea crítica, ética y eficaz (Barus et al., 2025; Kim et al., 2025).

Para alcanzar este fin, se han planteado cinco objetivos específicos. El primero es de naturaleza descriptiva: se busca caracterizar el perfil sociodemográfico y tecnológico de los estudiantes que utilizan estas herramientas (Barus et al., 2025). Esto implica no solo conocer sus datos demográficos básicos, sino también identificar qué plataformas son las más prevalentes en su ecosistema digital y con qué frecuencia las integran en sus quehaceres académicos (Kanont et al., 2024). El segundo objetivo se adentra en el núcleo de la experiencia subjetiva: se pretende describir y analizar las percepciones de los estudiantes sobre los beneficios y riesgos que asocian al uso de la IA, identificando las áreas donde su valoración es más positiva y aquellas que generan mayores inquietudes (Almassaad et al., 2024).

Los objetivos subsiguientes transitan de la descripción a la inferencia y el modelado. El tercer objetivo es examinar las relaciones que existen entre las distintas dimensiones de la percepción (beneficios, riesgos, actitud general, intención de uso) y explorar si existen diferencias significativas en estas percepciones en función de variables clave como el género o el nivel académico (Barus et al., 2025; Gruenhagen et al., 2024). El cuarto objetivo es de carácter exploratorio y aplica técnicas de machine learning no supervisado para identificar y caracterizar posibles perfiles o arquetipos de estudiantes. Bajo la hipótesis de que la población no es homogénea, sino que puede estar compuesta por segmentos con patrones actitudinales distintivos (Morell-Mengual et al., 2025). Finalmente, el quinto objetivo es predictivo: se propone desarrollar y evaluar modelos de machine learning supervisado capaces de predecir la intención de un estudiante de adoptar la IA generativa a largo plazo, identificando los factores que mejor explican esta decisión (Abdi et al., 2025; Nikolic, Wentworth, et al., 2024).

Estos objetivos se traducen en una serie de preguntas de investigación que actúan como la espina dorsal del análisis. La pregunta general que guía la obra

es: ¿Cuáles son las percepciones, patrones de uso y actitudes predominantes de los estudiantes universitarios hacia la inteligencia artificial generativa, y cómo pueden estos factores informar una integración pedagógica y ética de estas herramientas en la educación superior? (Chan & Hu, 2023). De esta pregunta central se derivan cuestiones más específicas: ¿Cuál es el perfil del estudiante usuario de IA? (Kim et al., 2025). ¿Qué beneficios y riesgos son los más sobresalientes por esta población? (Barus et al., 2025). ¿Existe una relación entre la valoración de su utilidad y la conciencia de sus peligros? (Ursavaş et al., 2025). ¿Es posible segmentar a los estudiantes en perfiles actitudinales coherentes? (Morell-Mengual et al., 2025) y, crucialmente, ¿qué variables permiten anticipar qué estudiantes integrarán estas herramientas de forma sostenida en su futuro académico y profesional? (Cabero-Almenara et al., 2025). La misión fundamental de este libro es dar respuesta a estas preguntas.

1.4. Justificación y aportes del estudio

La relevancia de una investigación no reside únicamente en la originalidad de su objeto de estudio, sino en su capacidad para generar conocimiento que sea a la vez significativo, oportuno y aplicable (Morell-Mengual et al., 2025). La presente obra se justifica por su triple contribución a los ámbitos académico, institucional y social, ofreciendo un valor tangible a cada uno de estos dominios (Bukar et al., 2024).

Desde el punto de vista académico, este libro se posiciona en la vanguardia de un campo de investigación emergente (Kizilcec et al., 2024). En un momento en que gran parte de la literatura sobre IA generativa en educación se encuentra aún en una fase teórica o cualitativa a pequeña escala, este trabajo ofrece una contribución metodológica y empírica sustancial (Ortiz-Bonnin & Blahopoulou, 2025). Su principal aporte es la presentación de un análisis cuantitativo a gran escala, basado en un instrumento psicométricamente validado y una muestra representativa (Fischer et al., 2024). Este enfoque permite trascender la anécdota para identificar tendencias y patrones estadísticamente significativos (Barus et al., 2025). Además, la obra se distingue por su enfoque interdisciplinario, al integrar conceptos de la teoría educativa, la psicometría y la

ciencia de datos (Tala et al., 2024). La aplicación de técnicas de machine learning, como el clustering de perfiles y los modelos predictivos, representa un avance metodológico en el estudio de la adopción tecnológica en educación, ofreciendo un nivel de análisis que va más allá de la estadística descriptiva e inferencial tradicional (Zaim et al., 2024). El libro no solo presenta resultados, sino que detalla una metodología replicable que puede servir de modelo para futuras investigaciones en otros contextos.

Para las instituciones de educación superior, la justificación de este estudio es eminentemente estratégica y pragmática (Smit et al., 2025). En un entorno caracterizado por la incertidumbre y la necesidad de una adaptación ágil, la toma de decisiones basada en evidencia es más crucial que nunca (Gallent Torres et al., 2023). Esta investigación proporciona a los gestores universitarios, a los responsables de innovación pedagógica y a los comités de currículo una radiografía precisa y detallada de su estudiantado. Los hallazgos pueden informar directamente el diseño de políticas institucionales sobre integridad académica que sean realistas y aplicables (Iulian et al., 2024). Permiten, además, la creación de programas de formación y alfabetización en IA que no sean genéricos, sino que estén segmentados y adaptados a los distintos perfiles de estudiantes identificados (Sallam et al., 2024). De igual manera, los resultados pueden inspirar un rediseño de las estrategias pedagógicas y evaluativas, orientando a los docentes sobre cómo integrar estas herramientas de manera crítica y creativa en el aula (Fischer et al., 2024). En definitiva, este libro ofrece a las instituciones una base empírica para pasar de una posición reactiva a una estrategia proactiva e informada.

Finalmente, la relevancia de la investigación se proyecta a la sociedad en su conjunto. La universidad es el espacio donde se está formando la próxima generación de profesionales, ciudadanos y líderes (Chiu, 2024). Su interacción con la IA generativa no es un mero asunto académico, sino un preludio de cómo la sociedad en general se relacionará con una de las tecnologías más transformadoras de la historia (L. Cutillas, 2025; Ruiz-Rojas et al., 2024). La capacidad de colaborar eficazmente con sistemas de IA, de discernir críticamente sus resultados, de navegar sus dilemas éticos y de comprender sus

implicaciones sociales se está convirtiendo rápidamente en una competencia fundamental del siglo XXI (Chiu, 2024; Jin et al., 2025).

Al estudiar cómo los universitarios actuales desarrollan (o no) esta competencia, este estudio arroja luz sobre la preparación de la próxima generación de la fuerza laboral (Fischer et al., 2024). Comprender sus percepciones sobre la ética algorítmica, la fiabilidad de la información y el equilibrio entre la cognición humana y la artificial es fundamental para anticipar los desafíos y oportunidades que la IA planteará a la sociedad en su conjunto (Barus et al., 2025; Fischer et al., 2024). La universidad actúa como un laboratorio de la futura simbiosis humano-máquina, por lo que investigar lo que sucede dentro de sus muros es una contribución esencial al debate más amplio sobre el futuro de nuestra sociedad digital (Haroud & Saqri, 2025; Qian, 2025).

1.5. Estructura de la obra


Para guiar al lector a través de la complejidad de los análisis y la riqueza de los hallazgos, esta obra ha sido organizada en una estructura capitular lógica y progresiva. Cada capítulo construye sobre el anterior, conduciendo al lector desde los fundamentos teóricos hasta las conclusiones y recomendaciones prácticas.

El Capítulo 2 establece el andamiaje conceptual de la investigación, presentando un marco teórico y una revisión del estado del arte. En él se definen los conceptos fundamentales de la inteligencia artificial, se explora la literatura académica más reciente sobre la adopción de estas tecnologías en la educación superior y se discuten los marcos teóricos que informan el análisis. El Capítulo 3 está dedicado al diseño metodológico, donde se detalla con transparencia el proceso de construcción y validación psicométrica del instrumento de recolección de datos, se describen las características de la muestra y el procedimiento de muestreo, y se explican las técnicas estadísticas y de machine learning que se aplicarán.

Los capítulos 4, 5 y 6 conforman el núcleo empírico del libro. El Capítulo 4 ofrece una caracterización exhaustiva de la muestra, presentando los resultados del

análisis descriptivo del perfil sociodemográfico y tecnológico de los participantes. El Capítulo 5 se adentra en el análisis estadístico de los resultados del cuestionario, exponiendo los hallazgos del análisis descriptivo de las percepciones, el estudio de correlaciones y las pruebas de diferencia de grupos. El Capítulo 6 eleva el nivel de análisis, presentando los resultados de la aplicación de técnicas de machine learning, tanto no supervisadas (clustering de perfiles) como supervisadas (modelos predictivos).

Finalmente, los dos últimos capítulos se dedican a la síntesis y la prospectiva. El Capítulo 7 presenta una discusión general y una triangulación de los hallazgos, donde se analizan e interpretan los resultados a la luz del marco teórico y se discuten sus implicaciones. El Capítulo 8 cierra la obra con las conclusiones finales y una serie de recomendaciones concretas dirigidas a los distintos actores del ecosistema universitario: gestores, docentes, estudiantes y futuros investigadores. Esta es la hoja de ruta propuesta para el análisis de una de las transformaciones más relevantes del tiempo actual.



CAPITULO 02

CONCEPTUALIZANDO LA INTERACCIÓN HUMANO- IA EN LA EDUCACIÓN

Conceptualizando la interacción Humano-IA en la educación

2.1. Fundamentación teórica y empírica

La irrupción de la IA generativa en el ámbito de la educación superior no es un mero fenómeno tecnológico; es un evento complejo que se sitúa en la intersección de la ciencia de la computación, la psicología del aprendizaje, la sociología de la tecnología y la ética aplicada (Shata & Hartley, 2025). Para analizarlo con la profundidad que merece, es indispensable trascender la descripción de sus manifestaciones superficiales y construir un sólido andamiaje conceptual (C. Wu et al., 2024). Este capítulo tiene como propósito establecer dicho andamiaje. Su función es doble: por un lado, clarificar los conceptos técnicos fundamentales que definen a la IA generativa, distinguiéndola de otras formas de IA; por otro, situar la presente investigación en el contexto del conocimiento académico existente, revisando tanto los estudios empíricos previos como los marcos teóricos que permiten interpretar la adopción y el impacto de estas herramientas (Nikolic, Wentworth, et al., 2024).

El recorrido que se propone en este capítulo está diseñado para guiar al lector en un proceso deductivo, desde los principios más generales de la IA hasta las discusiones más específicas sobre su aplicación en el aula universitaria (H. Wang et al., 2024). Se comenzará por desentrañar la terminología, ofreciendo una taxonomía clara que diferencia entre la IA general, la IA estrecha (narrow AI) y el subcampo específico de la IA generativa (Đerić et al., 2025). Posteriormente, se contextualizarán estos conceptos en el ecosistema de herramientas actuales, describiendo las arquitecturas y funcionalidades de plataformas como ChatGPT, Copilot y Gemini (Ursavaş et al., 2025).

Una vez establecidos los fundamentos técnicos, el capítulo abordará el estado del arte de la investigación empírica. Se realizará una revisión sistemática de la literatura internacional reciente, identificando los principales hallazgos, tendencias y vacíos de conocimiento en el estudio de la percepción, la adopción y las implicaciones éticas del uso de la IA por parte de los estudiantes (Ortiz-

Bonnin & Blahopoulou, 2025). Finalmente, se presentarán y analizarán los marcos conceptuales que informan el diseño y la interpretación de este estudio. Se explorará en profundidad el Modelo de Aceptación Tecnológica (TAM) como lente para comprender la adopción, y se complementará con discusiones sobre la alfabetización digital crítica, la ética algorítmica y las aportaciones de la psicología educativa (Greiner et al., 2023; K. C. Li et al., 2025). Este capítulo, por tanto, no es un mero repositorio de definiciones, sino el mapa conceptual y empírico que da sentido y rigor a los hallazgos que se presentarán en las secciones posteriores de esta obra.

2.2. Deconstruyendo la IA

El término "inteligencia artificial" ha transitado desde los confines de la ciencia de la computación hasta convertirse en un significativo ubicuo en el discurso público, a menudo cargado de connotaciones imprecisas y antropomórficas (Nikolic, Wentworth, et al., 2024; Shata & Hartley, 2025). Para un análisis académico riguroso, es imperativo deconstruir este concepto monolítico y establecer una taxonomía precisa que distinga sus diversas formas, capacidades y limitaciones (Cardona et al., 2023). La IA no es una entidad única, sino un vasto y heterogéneo campo científico dedicado al diseño de sistemas capaces de realizar tareas que, tradicionalmente, han requerido inteligencia humana (Đerić et al., 2025; Gallent Torres et al., 2023).

2.2.1. IA General (IAG) frente a IA Estrecha (Narrow AI)

En el nivel más alto de abstracción, el campo de la IA se ha estructurado históricamente en torno a dos aspiraciones paradigmáticas (Gallent Torres et al., 2023). La primera, y la más elusiva, es la Inteligencia Artificial General (IAG), referida en la literatura clásica como IA fuerte (Michel-Villarreal et al., 2023). El concepto alude a una inteligencia maquina hipotética que sería indistinguible de la humana en términos de amplitud y flexibilidad cognitiva (Sousa & Cardoso, 2025).

Una IAG no estaría confinada a un dominio específico; poseería una capacidad de razonamiento abstracto, comprensión del sentido común, conciencia de sí

misma, y la habilidad de transferir conocimiento de manera fluida entre dominios dispares (Gallent Torres et al., 2023; Greiner et al., 2023). Sería capaz de aprender cualquier tarea intelectual que un ser humano pueda realizar. Es crucial destacar que, a pesar de los avances exponenciales en el campo, la IAG permanece en el terreno de la especulación teórica (Michel-Villarreal et al., 2023). Los sistemas actuales, por muy sofisticados que parezcan, no poseen las características de generalidad, autonomía y comprensión profunda que definirían a una IAG (Greiner et al., 2023; Zhao et al., 2024).

En contraposición, la totalidad de los sistemas de IA operativos en la actualidad, desde los algoritmos de recomendación de Netflix hasta los sistemas de diagnóstico médico, se enmarcan en la categoría de Inteligencia Artificial Estrecha (Narrow AI) o IA débil (Gallent Torres et al., 2023). Estos sistemas están diseñados y optimizados para ejecutar una tarea específica o un conjunto muy restringido de ellas (Jiang et al., 2025). Aunque en estos dominios acotados pueden igualar o incluso superar el rendimiento humano, como en el caso de AlphaGo de DeepMind en el juego de Go, su "inteligencia" es especializada, quebradiza y carece de cualquier forma de comprensión del mundo (Cardona et al., 2023).

Un sistema de narrow AI no "sabe" lo que está haciendo; ejecuta patrones estadísticos con una eficiencia sobrehumana dentro de los límites para los que fue entrenado (Krzysztof & Wojciech, 2023). Su poder no radica en la comprensión, sino en la optimización y el reconocimiento de patrones a gran escala, pero carece de la plasticidad y la capacidad de generalización que son sellos distintivos de la cognición biológica (Cardona et al., 2023; Greiner et al., 2023).

2.2.2. La IA Generativa y su arquitectura subyacente

Dentro del vasto paradigma de la narrow AI, en los últimos años ha emergido un subcampo que ha provocado el cambio de fase que se presencia actualmente: la IA generativa (Barus et al., 2025). A diferencia de los sistemas de IA "analíticos" tradicionales, cuyo propósito es clasificar o predecir a partir de datos existentes (por ejemplo, un modelo de credit scoring), los modelos generativos están diseñados para crear artefactos nuevos y sintéticos que imitan las

propiedades estadísticas de los datos con los que fueron entrenados (Nikolic, Wentworth, et al., 2024). Este contenido puede ser texto, imágenes (como en los modelos de difusión DALL-E o Midjourney), música o código de programación (Jiang et al., 2025). La IA generativa no se limita a interpretar el mundo; lo utiliza como inspiración para generar nuevas realidades digitales (Cambra-Fierro et al., 2025).

El motor de esta revolución es una clase de modelos de aprendizaje profundo conocidos como Modelos de Lenguaje a Gran Escala (Large Language Models o LLMs) (Barus et al., 2025). La arquitectura que subyace a los LLMs más avanzados, como la familia de modelos GPT (Generative Pre-trained Transformer) de OpenAI o PaLM 2/Gemini de Google, es la arquitectura Transformer (Krzysztof & Wojciech, 2023; Oliveira et al., 2025).

El avance conceptual clave de la arquitectura Transformer fue el mecanismo de atención (attention mechanism) (Jiang et al., 2025; Krzysztof & Wojciech, 2023). Este mecanismo permite al modelo ponderar dinámicamente la importancia de diferentes palabras en una secuencia de entrada, sin importar su distancia, superando las limitaciones de las arquitecturas recurrentes (RNN) y de memoria a corto-largo plazo (LSTM) que dominaban previamente el Procesamiento de Lenguaje Natural (NLP) (Krzysztof & Wojciech, 2023). Esta capacidad para capturar relaciones contextuales complejas y a larga distancia es lo que permite a los LLMs generar texto de una coherencia y fluidez sin precedentes (Mourtajji & Arts-Chiss, 2024).

El proceso de entrenamiento de un LLM es una proeza de la computación a gran escala (Krzysztof & Wojciech, 2023). Consiste en una fase de pre-entrenamiento no supervisado, donde el modelo es expuesto a un corpus de datos textuales de dimensiones astronómicas (cientos de miles de millones de palabras) (Van Den Berg & Du Plessis, 2023). Durante esta fase, el modelo aprende a predecir la siguiente palabra en una secuencia, un objetivo aparentemente simple que, al ser escalado, obliga al modelo a internalizar patrones gramaticales, sintácticos, semánticos y factuales del lenguaje humano (Kolade et al., 2024).

Estos modelos son, en esencia, "loros estocásticos", sistemas que no comprenden el significado, sino que son maestros en la imitación de patrones

lingüísticos (Gallent Torres et al., 2023; Shanto et al., 2023). Tras el pre-entrenamiento, los modelos suelen pasar por una fase de ajuste fino (fine-tuning) supervisado y de alineación con la retroalimentación humana (Reinforcement Learning from Human Feedback - RLHF), procesos que buscan orientar el comportamiento del modelo para que sea más útil, honesto e inofensivo.

Es esta combinación de escala masiva, arquitectura Transformer y técnicas de alineación lo que ha dado lugar a las capacidades que se observan hoy en día (Krzysztof & Wojciech, 2023). Comprender esta base técnica es fundamental para desmitificar la IA generativa: no es magia, sino estadística a una escala monumental, un sistema de predicción probabilística que opera sin una comprensión semántica del mundo (Gallent Torres et al., 2023).

2.3. Mapeo de la investigación empírica internacional

La celeridad de la adopción de la IA generativa por parte de la comunidad estudiantil ha generado un desafío para la investigación académica, que opera en ciclos de publicación inherentemente más lentos (Dabis & Csáki, 2024). No obstante, desde finales de 2022 ha emergido un cuerpo de literatura empírica que comienza a trazar los contornos de este fenómeno (Huang & Mizumoto, 2024). La revisión de estos estudios iniciales, aunque preliminares, es crucial para contextualizar los hallazgos de la presente obra (Kizilcec et al., 2024).

Una primera línea de investigación se ha centrado en establecer la prevalencia de uso y la demografía de los usuarios (Baek et al., 2024). Estudios de encuesta a gran escala en universidades norteamericanas y europeas han revelado tasas de adopción sorprendentemente altas y rápidas, superando el 80% de la población estudiantil en menos de un año desde el lanzamiento de ChatGPT (Dabis & Csáki, 2024; Jiang et al., 2025). Estos estudios descriptivos han sido fundamentales para confirmar que no se está ante un fenómeno de nicho, sino frente a una transformación tecnológica de base amplia (Ursavaş et al., 2025). Han corroborado, además, la hegemonía de ChatGPT en el ecosistema de herramientas y han perfilado un patrón de uso integrado en las rutinas académicas, con una frecuencia predominante de uso semanal o mensual (H. Wang et al., 2024; Zaim et al., 2024). Sin embargo, muchos de estos estudios

iniciales carecen de un análisis más profundo sobre las diferencias entre disciplinas o niveles académicos (Ruiz-Rojas et al., 2024).

Un segundo y más prolífico cuerpo de literatura ha explorado las percepciones de los estudiantes sobre los beneficios y los riesgos (Barus et al., 2025; L. Wang & Ren, 2024). En cuanto a los beneficios, existe un consenso abrumador en la literatura en que los estudiantes valoran la IA generativa principalmente como una herramienta para potenciar la eficiencia y la productividad (Kizilcec et al., 2024; Sousa & Cardoso, 2025). Tareas como la redacción de borradores, el resumen de textos o la generación de código son percibidas como significativamente más rápidas (Chiu, 2024; Fischer et al., 2024). Más allá de la eficiencia, los estudiantes también reportan beneficios cognitivos, como la utilidad de la IA para explicar conceptos complejos de manera simplificada y para actuar como un catalizador en la fase de ideación o brainstorming (Chan & Hu, 2023; Nartey, 2024).

No obstante, esta percepción positiva está matizada por una conciencia crítica de los riesgos (Barus et al., 2025). La preocupación por la fiabilidad, la precisión y la tendencia de los modelos a "alucinar" (generar información falsa con aplomo) es, de manera consistente, el riesgo más citado en la literatura internacional (Kofinas et al., 2025). A esta le siguen las inquietudes sobre el impacto a largo plazo en el desarrollo del pensamiento crítico y la ética del uso, particularmente en lo que respecta a la integridad académica (Barus et al., 2025; Fischer et al., 2024). Esta coexistencia de una alta percepción de utilidad con una profunda conciencia de los riesgos parece ser la característica definitoria del usuario estudiantil actual (Barus et al., 2025; K. C. Li et al., 2025).

La cuestión de la integridad académica ha cristalizado como un campo de estudio en sí mismo (Gallent Torres et al., 2023). Las investigaciones iniciales sugieren que los estudiantes no poseen una visión monolítica sobre el tema (Barus et al., 2025; K. C. Li et al., 2025). Lejos de una dicotomía simple entre uso ético y fraude, los estudiantes parecen navegar un espectro de aceptabilidad (Gruenhagen et al., 2024; Smit et al., 2025). El consenso emergente es que el uso de la IA se percibe como legítimo cuando funciona como una herramienta de asistencia (para corregir gramática, sugerir ideas, mejorar la claridad), pero

se vuelve problemático cuando sustituye el esfuerzo cognitivo fundamental del estudiante (Gallent Torres et al., 2023; Smit et al., 2025). La falta de políticas institucionales claras ha generado una "zona gris" en la que los estudiantes operan basándose en su propia interpretación ética, lo que subraya la urgencia de desarrollar marcos normativos (Jiang et al., 2025; Ortiz-Bonnin & Blahopoulou, 2025).

A pesar de estos avances, la investigación presenta aún lagunas significativas que este libro busca abordar (El-Bayaa et al., 2025). Primero, la mayoría de los estudios se han mantenido en un nivel descriptivo (Bukar et al., 2024; Oc et al., 2025). Hay una notable escasez de investigaciones que apliquen análisis inferenciales más sofisticados para explorar las relaciones entre las percepciones o las diferencias entre subgrupos (Oc et al., 2025; Ortiz-Bonnin & Blahopoulou, 2025). Segundo, la literatura ha tendido a tratar a la población estudiantil como un todo homogéneo (Lai et al., 2023; Sergeeva et al., 2025). El uso de técnicas como el análisis de clústeres para identificar perfiles de usuarios con patrones actitudinales distintos es un área prácticamente inexplorada (Bhullar et al., 2024; Lai et al., 2023). Tercero, la aplicación de modelos predictivos de machine learning para entender los factores que impulsan la adopción a largo plazo es un campo incipiente (Balaskas et al., 2025; Oc et al., 2025). La presente investigación se posiciona directamente en esta frontera analítica, con el objetivo de aportar un nivel de profundidad y sofisticación que complemente y expanda los hallazgos descriptivos iniciales.

2.4. Marcos teóricos para modelar la interacción Humano-IA

Para interpretar los datos empíricos de manera significativa, es necesario anclarlos en marcos teóricos que proporcionen un lenguaje y una estructura para el análisis. Dada la naturaleza multifacética del fenómeno, este estudio se apoya en un conjunto de teorías y conceptos provenientes de la sociología de la tecnología, la educación y la ética.

2.4.1.El modelo de aceptación tecnológica (TAM) y sus limitaciones

El marco teórico más influyente para explicar la adopción de nuevas tecnologías es, sin duda, el Modelo de Aceptación Tecnológica (Technology Acceptance Model - TAM) (Huang & Mizumoto, 2024; K. C. Li et al., 2025). El TAM postula que la intención de un individuo de utilizar una tecnología está determinada principalmente por dos creencias fundamentales: la Utilidad Percibida (Perceived Usefulness - PU), es decir, la creencia de que la tecnología mejorará el rendimiento; y la Facilidad de Uso Percibida (Perceived Ease of Use - PEOU), la creencia de que su uso estará libre de esfuerzo (Lai et al., 2023; Linh, 2025). En el contexto de la IA generativa, la explosiva tasa de adopción puede ser explicada de manera elegante por el TAM: las interfaces conversacionales (alta PEOU) permitieron a los usuarios descubrir de inmediato su vasto potencial para una multitud de tareas académicas (alta PU) (Shata & Hartley, 2025). Este modelo proporciona variables clave para el análisis cuantitativo y permite formular hipótesis claras sobre la relación entre la percepción de utilidad y la intención de uso (Huang & Mizumoto, 2024).

Sin embargo, el TAM, en su formulación clásica, presenta limitaciones significativas para capturar la complejidad de la interacción con la IA generativa (K. C. Li et al., 2025). El modelo fue diseñado en una era de software de productividad determinista y no contempla las dimensiones de riesgo, ética y confianza que son intrínsecas a los sistemas probabilísticos y opacos como los LLMs (Balaskas et al., 2025). La decisión de usar (o no usar) ChatGPT no es análoga a la de usar un procesador de textos (Mourtajji & Arts-Chiss, 2024). Implica un cálculo de confianza en la fiabilidad de sus respuestas, una reflexión ética sobre la autoría y una valoración del riesgo de dependencia cognitiva (Shahzad et al., 2024). Por tanto, si bien el TAM es un punto de partida indispensable para modelar la dimensión utilitaria de la adopción, debe ser complementado con marcos que aborden estas nuevas complejidades (Balaskas et al., 2025).

2.4.2. La alfabetización en IA como competencia crítica

Para analizar el cómo de la adopción, más allá del por qué, se recurre al concepto de alfabetización en IA (AI Literacy), una evolución de la noción de alfabetización digital (Shi et al., 2025). La alfabetización en IA, no se limita a las habilidades instrumentales para usar sistemas de IA (Kizilcec et al., 2024). Es una competencia multidimensional que implica la capacidad de interactuar críticamente con estos sistemas, comprender sus principios fundamentales y evaluar sus implicaciones éticas (Shi et al., 2025; Zhao et al., 2024).

Aplicado a la IA generativa, esto significa que un estudiante "alfabetizado" no es simplemente aquel que domina el prompt engineering (Kizilcec et al., 2024). Es aquel que, además, es capaz de:

- Evaluar la procedencia y fiabilidad de la información generada: Comprender la naturaleza probabilística de los LLMs y la posibilidad de "alucinaciones", y poseer las habilidades para verificar la información de manera sistemática (Gallent Torres et al., 2023; Iulian et al., 2024).
- Reconocer y mitigar sesgos: Ser consciente de que los modelos, entrenados con datos históricos, pueden perpetuar sesgos sociales, y ser capaz de identificar y cuestionar estos sesgos en los resultados (El-Bayaa et al., 2025; Krzysztof & Wojciech, 2023).
- Navegar la ética de la autoría: Utilizar la IA como un colaborador intelectual sin traspasar la línea hacia el fraude académico, desarrollando un juicio ético sobre qué constituye un uso legítimo (Gallent Torres et al., 2023; Pavlenko & Syzenko, 2024).
- Comprender las implicaciones sociales: Tener una noción de los debates sobre el impacto de la IA en el mercado laboral, la privacidad de los datos y la equidad social (Barus et al., 2025; Q. Wu et al., 2025).

Las percepciones de los estudiantes sobre los riesgos, que se miden en el cuestionario de este estudio, pueden ser interpretadas como indicadores de su nivel de alfabetización crítica en IA (Chan & Hu, 2023). Este marco permite analizar no solo si los estudiantes usan la IA, sino la sofisticación y la criticidad de ese uso (Zhao et al., 2024).


2.4.3. Implicaciones para la psicología educativa y la pedagogía crítica

Para interpretar el impacto de la IA en el proceso de aprendizaje, es fundamental recurrir a los aportes de la psicología educativa y la pedagogía universitaria (Hong et al., 2025; Szűts et al., 2025). Desde la perspectiva de la teoría de la carga cognitiva, la IA generativa puede actuar como una poderosa herramienta para reducir la carga cognitiva extrínseca (el esfuerzo mental irrelevante para el aprendizaje, como la búsqueda de sintaxis de código o la reformulación de frases), liberando recursos cognitivos para que el estudiante se concentre en la carga cognitiva intrínseca (la complejidad inherente al material) y la carga cognitiva pertinente (el proceso de construcción de esquemas mentales) (Khan et al., 2025). Sin embargo, un uso inadecuado puede ser contraproducente, si el estudiante delega precisamente los procesos de esfuerzo mental que conducen al aprendizaje profundo (Hong et al., 2025).

Desde la teoría del aprendizaje autorregulado, la IA puede ser vista como un "agente externo" que puede apoyar o dificultar las tres fases del ciclo de autorregulación: la planificación (ayudando a estructurar un ensayo), la ejecución (monitorizando el progreso) y la reflexión (ofreciendo retroalimentación) (Lai et al., 2023). Una interacción madura implicaría que el estudiante utiliza la IA para mejorar sus propias capacidades metacognitivas, no para sustituirlas (Oliveira et al., 2025).

Una perspectiva de pedagogía crítica invita a cuestionar las relaciones de poder inherentes a estas tecnologías (Baek et al., 2024). ¿Quién diseña estos algoritmos? (Jiang et al., 2025) ¿Qué intereses económicos y culturales promueven? (Driessens & Pischetola, 2024) ¿Puede el uso de la IA fomentar un modelo de aprendizaje pasivo y "bancario", donde el estudiante simplemente consume y reproduce información, o puede ser apropiada como una herramienta para la praxis, la creación y el cuestionamiento crítico? (Sousa & Cardoso, 2025). Este marco analítico obliga a considerar no solo la eficacia cognitiva de la IA, sino también su impacto en la autonomía, la agencia y la conciencia crítica del estudiante (Kizilcec et al., 2024; Ortiz-Bonnin & Blahopoulou, 2025).

En su conjunto, la articulación de estos marcos teóricos, el TAM para la adopción, la alfabetización en IA para la competencia, y la psicología educativa y la pedagogía crítica para el impacto en el aprendizaje, proporciona un andamiaje conceptual robusto y multifacético (Greiner et al., 2023). Es a través de esta combinación de perspectivas que los datos empíricos de este estudio pueden ser interpretados de una manera que sea a la vez técnicamente informada, pedagógicamente relevante y socialmente consciente (Balaskas et al., 2025).



CAPITULO 03

DISEÑO METODOLÓGICO Y VALIDACIÓN DEL INSTRUMENTO

Diseño metodológico y validación del instrumento

3.1. Enfoque metodológico general del estudio

El diseño metodológico de esta investigación se estructura sobre tres pilares fundamentales que garantizan el rigor y la pertinencia del estudio. En primer lugar, se justifica la adopción de un enfoque cuantitativo-descriptivo como el más adecuado para caracterizar de manera sistemática y basada en evidencias un fenómeno emergente como el uso de la IA generativa en el ámbito universitario. En segundo lugar, se detalla el diseño secuencial del estudio, que incluyó una fase piloto crucial para la validación y refinamiento del instrumento de recolección de datos antes de su aplicación masiva y definitiva. Finalmente, se exponen los fundamentos teóricos y operativos que sustentaron la construcción del cuestionario, asegurando que las dimensiones exploradas respondieran a un marco conceptual sólido y relevante para los objetivos de la investigación.

3.1.1. Justificación del enfoque cuantitativo-descriptivo

La elección del enfoque cuantitativo-descriptivo responde a la necesidad de abordar el fenómeno emergente del uso de la IA generativa (IAG) en entornos académicos desde una perspectiva empírica, sistemática y basada en evidencias (Almassaad et al., 2024). Al tratarse de un objeto de estudio complejo, dinámico y con múltiples niveles de análisis, que incluye prácticas individuales, percepciones, actitudes, riesgos, oportunidades y demandas institucionales, se optó por construir un instrumento estructurado que permitiera captar patrones estables de comportamiento y opinión entre estudiantes universitarios (Barus et al., 2025; Gallent Torres et al., 2023).

La modalidad descriptiva se seleccionó por su capacidad para caracterizar de forma precisa los rasgos y dimensiones más representativas del fenómeno, sin imponer desde el inicio hipótesis explicativas rígidas o relaciones causales predefinidas (Cabero-Almenara et al., 2025; Gasaymeh et al., 2024). En este sentido, la investigación se orientó a registrar las formas en que los estudiantes se relacionan con herramientas de IAG, sus percepciones sobre su utilidad o riesgo, su conocimiento práctico, así como sus expectativas frente al rol

institucional en su regulación o aprovechamiento (Almassaad et al., 2024; Sousa & Cardoso, 2025). Este enfoque no excluye la posibilidad de futuros análisis correlacionales o explicativos, pero en esta primera fase busca construir un mapa detallado de la situación actual (Barus et al., 2025; Oc et al., 2025).

3.1.2. Diseño secuencial del estudio: piloto y aplicación definitiva

Uno de los aportes metodológicos clave de esta investigación radica en su diseño en dos fases: una inicial de prueba piloto, seguida por una aplicación final masiva del instrumento reformulado. Esta estructura metodológica fue concebida con el fin de garantizar una construcción progresiva, iterativa y validada del cuestionario, basada no solo en revisión teórica, sino también en retroalimentación directa proveniente del público objetivo.

El desarrollo del estudio piloto fue una fase crucial de recolección de datos, diseñada para evaluar y corregir el instrumento. Se aplicó una versión inicial del cuestionario a una muestra intencionada de estudiantes universitarios, lo que no solo proporcionó datos preliminares, sino también información crítica sobre la calidad de los ítems, la claridad de las instrucciones, la adecuación de las escalas y la relevancia de los temas. Esta estrategia permitió optimizar el instrumento antes de su aplicación a gran escala, lo que aumentó significativamente su validez y efectividad.

3.1.3. Fundamentos teóricos y operativos del instrumento

La construcción del cuestionario se fundamentó en un marco teórico que integró aportes de los estudios sobre innovación educativa, competencias digitales, ética tecnológica y gobernanza de la IA. En particular, se consideraron investigaciones recientes sobre los impactos pedagógicos de la IA generativa, las estrategias de uso adoptadas por estudiantes, y las políticas institucionales emergentes en el ámbito de la educación superior. Este marco se operacionalizó en dimensiones temáticas que guiaron la organización del cuestionario: familiaridad tecnológica, usos académicos, percepciones y actitudes, riesgos percibidos, regulación institucional y prácticas docentes.

Cada una de estas dimensiones fue traducida en bloques temáticos del cuestionario, integrando preguntas cerradas de opción única o múltiple, escalas

tipo Likert, y preguntas abiertas con instrucción orientadora. Se priorizó un lenguaje claro, inclusivo y adaptado al nivel académico de los participantes, evitando tecnicismos innecesarios que pudieran obstaculizar la comprensión o generar sesgos por desconocimiento terminológico.

3.2. Diseño y estructura de la encuesta piloto

La fase piloto fue una etapa fundamental del proceso metodológico, diseñada con el propósito central de validar y refinar el instrumento de recolección de datos. En este apartado se describe su implementación, detallando las características operativas de la encuesta, la cual fue distribuida a través de Google Forms a una muestra de 113 estudiantes. Se expone la organización temática del cuestionario, estructurado en seis bloques que abarcan desde datos sociodemográficos hasta percepciones sobre riesgos y ventajas de la IAG. Finalmente, se destaca un componente innovador de esta fase: la inclusión de una sección donde los propios participantes evaluaron la calidad del instrumento, aportando retroalimentación directa sobre su claridad, relevancia y extensión.

3.2.1. Propósito de la fase piloto

La encuesta piloto tuvo como finalidad central evaluar la funcionalidad inicial del instrumento diseñado para estudiar el uso de IA generativa (IAG) en contextos universitarios. Esta fase fue concebida no solo como un paso previo, sino como una etapa crítica de validación empírica y técnica del cuestionario. Su implementación permitió observar el comportamiento real de los ítems en campo, así como recopilar retroalimentación de los participantes, quienes no solo aportaron datos sobre el fenómeno investigado, sino también información valiosa sobre la calidad del propio instrumento.

El cuestionario fue aplicado bajo el título “Uso de Inteligencia Artificial Generativa en el contexto académico (Encuesta piloto)”, y estuvo disponible entre el 7 y el 14 de mayo de 2025. Durante este período, se obtuvo un total de 113 respuestas válidas de estudiantes universitarios activos, lo que permitió realizar análisis estadísticos preliminares y obtener una muestra representativa para propósitos exploratorios.

3.2.2. Características operativas del instrumento

El instrumento fue implementado mediante la plataforma Google Forms, lo que facilitó su distribución digital y su acceso multiplataforma. La decisión de emplear este medio respondió a su amplia familiaridad entre el público objetivo, su compatibilidad con dispositivos móviles y su capacidad de almacenar datos estructurados en tiempo real.

El formulario comenzaba con una sección informativa que detallaba los objetivos del estudio, los criterios de inclusión (ser estudiante universitario activo), la duración estimada (10 minutos), el carácter anónimo y confidencial de la participación, y un canal de contacto para resolver dudas. Estos elementos fueron clave para garantizar la adhesión voluntaria de los participantes y el cumplimiento de principios éticos básicos en la investigación social.

Durante su diseño, se aplicaron principios de usabilidad para reducir la tasa de abandono, tales como una estructura secuencial coherente, campos obligatorios para asegurar la completitud de los datos y mensajes de validación en aquellos ítems donde podía haber ambigüedad.

3.2.3. Organización temática del cuestionario piloto

La encuesta piloto fue construida en torno a seis bloques temáticos, cada uno de los cuales se orientó a captar diferentes dimensiones del fenómeno estudiado:

- a) Datos sociodemográficos: En esta sección se registraron variables básicas como edad, género, carrera universitaria y nivel de estudios. Estos datos permitieron segmentar la muestra y explorar correlaciones posteriores.
- b) Familiaridad con herramientas de IAG: Se incluyeron preguntas cerradas para identificar qué plataformas de IA conocían y utilizaban los estudiantes, con opciones de frecuencia de uso.
- c) Usos académicos y funciones específicas: Aquí se indagó sobre los fines académicos para los cuales los estudiantes recurrían a estas herramientas, como generación de ideas, revisión ortográfica o resolución de tareas.

- d) Percepciones sobre ventajas y riesgos: Este bloque contenía afirmaciones valoradas en escala Likert, orientadas a capturar la valoración de los estudiantes sobre aspectos positivos y negativos del uso de IA generativa.
- e) Opiniones sobre integración institucional y docente: En esta sección se exploraron percepciones sobre cómo la universidad y el profesorado deberían posicionarse frente a estas tecnologías.
- f) Preguntas abiertas: Finalmente, se propusieron seis preguntas de respuesta libre para recoger perspectivas más cualitativas sobre riesgos, recomendaciones y evaluación de la propia encuesta.

3.2.4. Evaluación de la calidad del instrumento por los participantes

Uno de los elementos innovadores del cuestionario piloto fue la inclusión de un bloque específico dedicado a que los propios participantes evaluaran la encuesta que acababan de responder. Esta sección contenía cinco ítems en escala Likert, centrados en los siguientes aspectos: claridad de las preguntas, cobertura temática, relevancia del contenido, motivación para responder, y adecuación de la extensión total.

Esta autoevaluación del instrumento permitió obtener una medida empírica de su funcionalidad desde la experiencia directa del usuario, y fue clave para identificar ajustes necesarios en términos de redacción, estructura y longitud. Las respuestas fueron sometidas a un análisis técnico que se expondrá en la sección siguiente.

3.3. Análisis técnico de resultados del piloto

En este apartado se presenta el análisis técnico exhaustivo de los resultados obtenidos en la fase piloto, cuyo valor estratégico fue fundamental para la validación empírica del instrumento. Se aborda una evaluación multicomponente que integra tanto métricas cuantitativas, como el análisis de fiabilidad mediante alfa de Cronbach y las correlaciones entre ítems, como el análisis cualitativo de las respuestas abiertas. El objetivo de este examen es identificar con precisión

las fortalezas y, de manera crítica, las debilidades del cuestionario, incluyendo el comportamiento de ítems específicos, inconsistencias internas y fallos estructurales. En conjunto, los hallazgos aquí detallados proporcionaron la evidencia empírica indispensable para justificar la reformulación, optimización y reorganización del instrumento en su versión definitiva.

3.3.1. Propósito metodológico y valor estratégico del piloto

La fase piloto constituyó un eje fundamental del proceso metodológico, no solo como una instancia de prueba técnica del cuestionario, sino como un espacio estratégico para la validación empírica del instrumento. Implementada entre el 7 y el 14 de mayo de 2025, la encuesta piloto tuvo como objetivo principal identificar fortalezas, debilidades, ambigüedades y oportunidades de mejora a partir de una muestra real de estudiantes universitarios. En total se recolectaron 113 respuestas válidas. Este número resultó suficiente para realizar análisis robustos de consistencia interna, correlaciones entre ítems, revisión de sesgos y codificación temática de respuestas abiertas.

El piloto sirvió para evaluar la pertinencia teórica y estadística de las preguntas, así como su impacto cognitivo en los participantes. Adicionalmente, permitió revisar la secuencia y organización de los bloques temáticos, la claridad de las instrucciones y la funcionalidad de la plataforma digital utilizada. En conjunto, funcionó como un dispositivo de validación multicomponente que proporcionó información clave para consolidar la versión definitiva del instrumento.

3.3.2. Evaluación cuantitativa de percepción del instrumento

Al final del cuestionario se incluyó un bloque de cinco preguntas para que los encuestados evaluaran el instrumento en una escala de 1 (muy en desacuerdo) a 5 (muy de acuerdo). El análisis descriptivo de estas variables ofreció los resultados presentados en la Tabla 1.

Tabla 1

Estadísticos descriptivos de la evaluación del instrumento piloto

Métrica de evaluación	Media	Desviación Estándar
Claridad de las preguntas	4.04	1.05
Cobertura temática	2.96	1.23
Relevancia e interés	3.96	1.08
Motivación para responder	3.78	1.16
Extensión adecuada	3.73	1.11

Nota: El ítem "Cobertura temática" fue diseñado como una pregunta de control de atención con un tópico ajeno a la investigación (Autores, 2025).

Los valores presentados en la Tabla 1 reflejan una percepción mayoritariamente positiva en aspectos clave como la claridad ($M = 4.04$) y la relevancia ($M = 3.96$). El ítem "Cobertura temática" fue diseñado intencionadamente como una pregunta de control de atención para validar la calidad de las respuestas, utilizando una afirmación deliberadamente ajena al tema de estudio: "La encuesta cubre todos los aspectos importantes sobre la crisis energética".

La media obtenida en este ítem ($M = 2.96$), significativamente más baja que las demás, se interpreta como un resultado exitoso. Confirma que los participantes estaban prestando atención al contenido de las preguntas y respondieron de forma lógica a una incongruencia. Por tanto, esta puntuación no evidencia una debilidad del instrumento, sino que valida la fiabilidad de los datos recogidos en el piloto.

3.3.3. Análisis de confiabilidad interna (alfa de Cronbach)

Para comprobar la consistencia interna del bloque de evaluación del instrumento, se calculó el coeficiente alfa de Cronbach (Al-Abdullatif & Alsubaie, 2024; Lai et al., 2023). El resultado obtenido fue de $\alpha = 0.892$, lo que representa un nivel de fiabilidad excelente según los estándares metodológicos. Este valor confirma que los ítems evaluativos (excluyendo la pregunta de control) medían dimensiones estrechamente relacionadas de la experiencia del encuestado (Shahzad et al., 2024; Sousa & Cardoso, 2025). Este hallazgo validó la estructura del bloque y confirmó que los juicios de los estudiantes sobre claridad, cobertura, motivación y extensión formaban parte de una misma dimensión evaluativa coherente (Acosta-Enriquez et al., 2024; Van Niekerk et al., 2025).

3.3.4. Correlaciones entre los ítems evaluativos

Se llevó a cabo una matriz de correlaciones de Pearson entre los cinco ítems evaluativos, confirmando la interrelación lógica entre ellos. La relación entre la claridad y la relevancia de las preguntas fue de 0.82, indicando una asociación muy fuerte. Asimismo, la correlación entre relevancia y motivación fue de 0.80, lo que implica que cuando los temas se perciben como importantes, se incrementa el compromiso con la encuesta. Finalmente, la correlación entre la cobertura temática y la extensión fue de 0.76. Estas fuertes asociaciones reforzaron la necesidad de optimizar la economía de ítems y evitar formulaciones que pudieran generar solapamientos en la percepción del estudiante.

3.3.5. Comportamiento de ítems y sesgos de respuesta

El piloto reveló la existencia de preguntas con escaso poder discriminativo. Un caso paradigmático fue el ítem “Las herramientas de inteligencia artificial generativa me ayudan a completar mis tareas académicas de forma más eficiente”, donde un 84.9% de los participantes se posicionó en “de acuerdo” o “totalmente de acuerdo”, limitando su capacidad para discriminar.

En el extremo opuesto, el ítem “Me preocupa que depender del uso de herramientas de inteligencia artificial generativa pueda afectar mi capacidad de pensar críticamente” obtuvo un 30.1% de respuestas en la categoría “neutral”. Esta tendencia fue interpretada como un indicio de ambigüedad o falta de posicionamiento, lo que llevó a la decisión de incluir ejemplos concretos en la encuesta final para facilitar una reflexión más informada.

3.3.6. Inconsistencias internas y reformulación de escalas

La revisión de las respuestas permitió detectar inconsistencias notorias. Se identificaron 10 casos de estudiantes que declararon usar herramientas de IA “Nunca o Rara vez” y, sin embargo, más adelante afirmaron sentirse “Neutral”, “Familiarizados” o “Muy familiarizados” con ellas. Este tipo de contradicción evidenció un problema semántico en el uso del término “familiaridad”. Como respuesta, en el rediseño del instrumento se reemplazó esta formulación por escalas de frecuencia más concretas y objetivas.

3.3.7.Codificación temática del contenido abierto

Las preguntas abiertas fueron una fuente invaluable de información cualitativa. Las respuestas se agruparon en categorías temáticas emergentes:

- Beneficios académicos: Mencionados de forma recurrente fueron la mejora en la redacción, la estructuración de ideas, el acceso rápido a explicaciones y el ahorro de tiempo.
- Riesgos percibidos: Los más citados fueron la pérdida de pensamiento crítico, la dependencia tecnológica, la desinformación y el plagio.
- Propuestas y sugerencias: Se enfocaron en la necesidad de guiar al estudiantado, integrar la IA en el currículo con reglas claras y fomentar un uso ético y responsable.

El tono general de las respuestas fue constructivo, lo que motivó la inclusión, en la encuesta final, de ítems más específicos que permitieran captar en mayor detalle los dilemas éticos y las expectativas institucionales.

3.3.8.Evaluación estructural del cuestionario

El análisis global del piloto identificó debilidades estructurales clave: redundancias entre preguntas, la formulación errónea de ítems como el de la "crisis energética", y un ordenamiento poco intuitivo de los bloques. Estas deficiencias, detectadas gracias al análisis técnico y las observaciones cualitativas, justificaron una reorganización completa de la estructura del cuestionario final. Los ítems se agruparon por dimensiones conceptuales claras, se armonizó la longitud de las secciones y se optimizó la navegación para garantizar una experiencia más fluida y coherente para el encuestado.

3.4. Rediseño del instrumento

A continuación, se detalla el proceso de rediseño del cuestionario, una fase metodológica fundamental que tradujo los hallazgos del estudio piloto en un instrumento final optimizado. El rediseño implicó una reconstrucción sustantiva que abarcó desde la consolidación y reorganización de los bloques temáticos hasta la reformulación precisa de ítems y escalas para mejorar su claridad y

capacidad discriminativa. Asimismo, el instrumento se enriqueció con la incorporación de nuevos contenidos derivados del análisis cualitativo, al tiempo que se aplicó una reducción estratégica de la extensión para eliminar redundancias.

3.4.1.Consideraciones iniciales para el rediseño

La revisión exhaustiva del cuestionario piloto reveló oportunidades claras de mejora que motivaron una reconfiguración del instrumento original. Si bien la encuesta piloto fue bien valorada por los participantes, el análisis técnico evidenció problemas de redacción, ambigüedad conceptual, escasa discriminación en algunos ítems, redundancias y una secuenciación poco fluida. El rediseño no consistió en simples ajustes cosméticos, sino en una reconstrucción sustantiva basada en los principios de validez de contenido, claridad lingüística, adecuación temática y eficiencia.

Desde el punto de vista metodológico, el proceso de rediseño partió del principio de que un cuestionario debe ser comprensible, relevante, estructuralmente coherente y sensible a las experiencias reales del público objetivo. En ese sentido, la encuesta final fue el resultado de un ejercicio de integración entre el conocimiento técnico, los datos empíricos del piloto y la voz directa de los encuestados.

3.4.2.Consolidación y reorganización temática de bloques

La primera acción en el proceso de rediseño fue la reorganización temática del instrumento. A partir del diagnóstico estructural del piloto, se reordenaron los bloques de preguntas para asegurar una progresión lógica y conceptual. La encuesta final quedó organizada en seis secciones claramente diferenciadas, con una secuencia que acompaña el tránsito natural del encuestado desde lo general a lo específico:

- 1) Datos sociodemográficos y académicos: Incluye preguntas sobre edad, género, área y año de estudios.
- 2) Familiaridad y uso de herramientas de IA: Esta sección indaga sobre las plataformas utilizadas, la frecuencia de uso y el nivel de familiaridad autopercebido por el estudiante.

- 3) Percepción sobre beneficios y ventajas: Un bloque de ítems en escala Likert que explora la valoración del estudiantado sobre el impacto positivo de la IA en su aprendizaje y eficiencia.
- 4) Percepción sobre riesgos y dilemas éticos: Contiene ítems en escala Likert centrados en las preocupaciones sobre la fiabilidad de la información, el plagio, la privacidad y el impacto en el pensamiento crítico.
- 5) Opinión sobre el rol institucional y docente: Agrupa las expectativas de los estudiantes sobre cómo la universidad y sus profesores deberían abordar la integración de la IA, incluyendo la necesidad de políticas claras y formación.
- 6) Preguntas abiertas complementarias: Una sección final para recoger percepciones cualitativas sobre los mayores beneficios, riesgos, recomendaciones para docentes y propuestas para la institución.

Cada sección fue diseñada con base en constructos teóricos bien definidos y en patrones de respuesta observados en el piloto. Esta estructuración buscó tanto optimizar la navegación como facilitar la posterior codificación y análisis estadístico. Además, permitió evitar solapamientos entre ítems y garantizar una distribución balanceada del contenido.

3.4.3.Reformulación de ítems y escalas de respuesta

Uno de los principales ajustes fue la reformulación de múltiples ítems que habían mostrado limitaciones. Preguntas muy generales en el piloto fueron desagregadas en la versión final en ítems específicos, tales como “Utilizo herramientas de IA para redactar introducciones” o “Solicito explicaciones teóricas usando IA”.

Esta especificidad permitió captar el uso de la IA en distintas fases del proceso académico, ampliando el valor analítico del instrumento. Además, se ajustaron las escalas de respuesta para mejorar su capacidad de diferenciación, adoptando categorías ordinales claramente definidas (“Nunca”, “Rara vez”, “A veces”, “Frecuentemente”, y “Siempre”). Las escalas de percepción, por su parte, se mantuvieron en formato Likert de cinco puntos, pero con mejoras lingüísticas que facilitaron la toma de posición por parte del encuestado.

3.4.4. Incorporación de nuevos contenidos del análisis cualitativo

Una contribución significativa del piloto fue la emergencia de temas no contemplados originalmente. A partir de la codificación de las respuestas abiertas, se identificaron demandas relacionadas con la integración curricular de la IA, la necesidad de formación ética y la preocupación por el plagio.

En consecuencia, se incorporaron nuevos ítems orientados a captar estas dimensiones emergentes. Por ejemplo, se introdujeron afirmaciones como “Mis docentes deberían enseñar a usar IA de manera responsable” o “Me preocupa que otros estudiantes usen IA para obtener ventajas desleales”. Estas nuevas preguntas permitieron captar no solo percepciones individuales, sino también valores sociales y expectativas institucionales.

3.4.5. Reducción estratégica de redundancias y extensión

Si bien el cuestionario piloto fue valorado positivamente en términos de longitud, algunas observaciones indicaron cierto nivel de repetición temática y redundancia de contenidos. En el rediseño, se aplicaron criterios de parsimonia metodológica, que llevaron a eliminar o fusionar preguntas que no ofrecían diferenciación significativa.

El número total de ítems cerrados en el instrumento final fue de 35, frente a los 42 del piloto. Esta reducción obedeció no a una simplificación del contenido, sino a una reestructuración interna que permitió captar las dimensiones de interés con mayor precisión y con menos preguntas. Por ejemplo, en lugar de múltiples preguntas sobre “ventajas de la IA”, se optó por construir una batería unificada de afirmaciones con escalas Likert que abordaban distintas funciones de manera paralela y estandarizada. Este diseño facilitó no solo la comprensión por parte del encuestado, sino también la posterior aplicación de análisis factoriales y pruebas de consistencia interna.

Por otro lado, se revisó y optimizó la sección de preguntas abiertas, dejando un total de cinco preguntas seleccionadas cuidadosamente para captar aspectos cualitativos complementarios: el mayor beneficio percibido, el mayor riesgo, una recomendación para el profesorado, una propuesta para la institución y la

identificación de la asignatura de mayor uso. Estas preguntas fueron reformuladas para ser más focalizadas y menos abiertas, lo que facilitó su codificación posterior sin perder riqueza expresiva.

3.4.6. Optimización del entorno digital y navegabilidad

Finalmente, se realizaron ajustes técnicos en la interfaz digital del cuestionario en Google Forms. Se optimizó el diseño visual con encabezados claros, segmentación de secciones y mensajes de progreso. Esta estructura ayudó a reducir la fatiga del encuestado y a mantener su atención. Además, se activaron mecanismos automáticos de validación de respuestas para asegurar la calidad de los datos recolectados.

3.5. Validación del instrumento definitivo

Una vez rediseñado el cuestionario, se sometió a un riguroso proceso de validación empírica utilizando los datos de la aplicación final a una muestra de 474 estudiantes (Lai et al., 2023). Esta sección detalla los resultados de dicho proceso, que se abordó desde una perspectiva multidimensional para garantizar la robustez del instrumento (Abdi et al., 2025; Ortiz-Bonnin & Blahopoulou, 2025). Se presentan los análisis de confiabilidad interna mediante el coeficiente alfa de Cronbach, se examina la validez conceptual a través de la matriz de correlaciones y se explora la validez de constructo mediante un análisis factorial exploratorio (Cabero-Almenara et al., 2025).

3.5.1. Propósito y enfoque de la validación

Tras el rediseño, fue fundamental someter la nueva versión a un riguroso proceso de validación empírica para evaluar la calidad de las mediciones y la estructura interna del instrumento (Lai et al., 2023). El proceso se desarrolló a partir de los datos obtenidos en la aplicación final, realizada entre el 19 de mayo y el 8 de junio de 2025. La muestra final fue de 474 estudiantes universitarios, un tamaño que permitió aplicar técnicas estadísticas robustas como pruebas de fiabilidad y análisis de correlación, siguiendo los principios de la psicometría (Lai et al., 2023; Shahzad et al., 2024).

3.5.2. Análisis de confiabilidad interna

Se calcularon los coeficientes alfa de Cronbach para las cinco subescalas temáticas del instrumento, diseñadas para medir constructos específicos (Lai et al., 2023; Zaim et al., 2024). Para ello, las respuestas en escala Likert se convirtieron a valores numéricos (1 = Totalmente en desacuerdo, 5 = Totalmente de acuerdo) (Acosta-Enriquez et al., 2024). Los resultados, que confirman una alta y consistente fiabilidad interna, se presentan en la Tabla 2.

Tabla 2

Análisis de confiabilidad de las subescalas del instrumento final

Subescala	Número de ítems	Alfa de Cronbach
Percepción de beneficios	7	0.873
Percepción de riesgos y ética	7	0.801
Rol docente	6	0.890
Rol institucional	6	0.908
Familiaridad y uso	3	0.784

Nota: N = 474. Los ítems de las subescalas fueron codificados en una escala de 1 (Totalmente en desacuerdo) a 5 (Totalmente de acuerdo) para el cálculo del coeficiente (Autores, 2025).

Todos los coeficientes superan ampliamente el umbral recomendado de 0.70, lo que indica que los ítems de cada subescala miden de forma consistente el mismo constructo subyacente (Cabero-Almenara et al., 2025; Shahzad et al., 2024). La fiabilidad es notablemente alta (cercana a 0.90) en las escalas de Rol Docente y Rol Institucional. Considerando los 29 ítems principales de percepción (escalas de la 1 a la 4), el valor de alfa de Cronbach global fue de $\alpha = 0.925$, lo que evidencia una excelente confiabilidad general del cuestionario.

3.5.3. Análisis de correlaciones coherencia interna

Se examinó la matriz de correlaciones de Pearson entre las puntuaciones medias de las subescalas para verificar la estructura conceptual del instrumento. Los hallazgos clave son consistentes con las hipótesis teóricas:

- Se encontró una correlación positiva y fuerte entre la Percepción de Beneficios y una mayor Frecuencia de Uso ($r = 0.53$), lo que sugiere que quienes más valoran las ventajas de la IA son quienes más la utilizan.
- La Percepción de Riesgos mostró una correlación negativa y débil con la Percepción de Beneficios ($r = -0.28$), indicando que ambas percepciones, aunque relacionadas, son constructos relativamente independientes.

- Se observó una correlación positiva y fuerte entre la demanda de un mayor involucramiento del Rol Docente y del Rol Institucional ($r = 0.78$). Esto sugiere que los estudiantes que esperan más de sus profesores en materia de IA también esperan más de la universidad en general.
- Finalmente, una mayor Percepción de Riesgos se asoció moderadamente con una mayor demanda de implicación tanto del Rol Docente ($r = 0.45$) como del Rol Institucional ($r = 0.44$). Esto confirma que la conciencia de los peligros está vinculada a una mayor expectativa de guía y regulación.

Estas relaciones brindan un sólido respaldo empírico a la validez conceptual del cuestionario, mostrando que las dimensiones se comportan de la manera teóricamente esperada (Cabero-Almenara et al., 2025; Lai et al., 2023).

3.5.4.Exploración preliminar de estructura factorial

Para evaluar la validez de constructo, se realizó un Análisis Factorial Exploratorio (AFE) sobre los 26 ítems de las escalas de percepción (Beneficios, Riesgos, Rol Docente y Rol Institucional) (Marengo et al., 2025; Oliveira et al., 2025). Se utilizó el método de extracción de máxima verosimilitud con rotación Varimax (Aguilos & Fuchs, 2024; Iulian et al., 2024).

Los resultados del AFE sugieren una estructura de cuatro factores principales que explican conjuntamente el 60.1% de la varianza total, un valor considerado robusto. Estos cuatro factores se alinean claramente con la organización temática del cuestionario:

- Factor 1. Rol Institucional y Docente (explica el 32.5% de la varianza).
- Factor 2. Beneficios Percibidos (explica el 12.0% de la varianza).
- Factor 3. Riesgos de Integridad y Ética (explica el 9.4% de la varianza).
- Factor 4. Riesgos de Fiabilidad y Dependencia (explica el 6.2% de la varianza).

La carga factorial de la mayoría de los ítems en sus respectivos factores fue superior a 0.50 (Namatovu & Kyambade, 2025). Este análisis confirma empíricamente que la agrupación de preguntas por bloques no fue arbitraria, sino que responde a una lógica conceptual sólida y coherente, validando la estructura del instrumento (Lai et al., 2023; Q. Wu et al., 2025).

3.5.5. Validación de contenido y claridad interpretativa

Además de los análisis estadísticos, se solicitaron retroalimentaciones cualitativas a un subgrupo de estudiantes ($n = 15$) (Marengo et al., 2025). Los comentarios recogidos permitieron corroborar que las instrucciones eran claras, las opciones de respuesta estaban bien diferenciadas y la progresión temática era adecuada (Barakat, 2025). La mayoría expresó sentirse cómodo con la duración y redacción del instrumento (K. C. Li et al., 2025).

3.5.6. Conclusiones sobre la validación del instrumento

En conjunto, los resultados del proceso de validación evidenciaron que el cuestionario definitivo no solo superaba en rendimiento técnico al piloto, sino que presentaba una estructura estadísticamente sólida. La alta confiabilidad interna de sus escalas ($\alpha > 0.78$), las correlaciones teóricamente coherentes entre sus dimensiones y una estructura factorial clara y robusta, permiten afirmar que el instrumento cumple con los estándares de calidad requeridos para estudios empíricos en contextos educativos.

Esta versión final del cuestionario constituyó, por tanto, una herramienta válida y fiable para captar con precisión el uso, la percepción y el impacto de la IA generativa entre estudiantes universitarios.

3.6. Consideraciones finales y criterios éticos

Este último apartado del capítulo ofrece una reflexión integral sobre el proceso de investigación. Se inicia con un balance del recorrido metodológico, se exponen con transparencia las limitaciones del estudio y se proponen recomendaciones para futuras investigaciones. Un pilar fundamental de esta sección es la descripción detallada de las consideraciones éticas que rigieron cada etapa del proceso.

3.6.1. Reflexión metodológica integral

El desarrollo metodológico de este estudio se desplegó como un proceso progresivo, sistemático y sustentado empíricamente. La aplicación de una encuesta piloto sirvió como base para un rediseño profundo del cuestionario.

Posteriormente, la implementación de la versión final sobre una muestra de 474 estudiantes consolidó su validez técnica, estructural y conceptual.

Desde una perspectiva global, el diseño metodológico integró diversas técnicas estadísticas en diálogo constante con la retroalimentación cualitativa de los participantes. Esta combinación permitió articular una propuesta investigativa que buscó no solo eficiencia, sino también precisión y profundidad. Una de las principales fortalezas del proceso fue el enfoque iterativo aplicado, que elevó el rigor del estudio, asegurando que las decisiones metodológicas respondieran a criterios estadísticos, pedagógicos, éticos y comunicativos.

3.6.2.Limitaciones técnicas y recomendaciones

Pese a los niveles elevados de confiabilidad alcanzados, es importante señalar algunas limitaciones. En primer lugar, se recomienda complementar el análisis factorial exploratorio con un análisis factorial confirmatorio en investigaciones posteriores para validar de forma más rigurosa la estructura de constructos.

En segundo lugar, la validez externa del cuestionario se encuentra condicionada por el hecho de que los datos provienen de una sola institución de educación superior. Resulta recomendable replicar el estudio en contextos diversos para ampliar la generalización de los hallazgos. Asimismo, debe subrayarse que el fenómeno estudiado es dinámico, por lo que todo instrumento diseñado en este campo requiere actualizaciones periódicas.

3.6.3.Consideraciones éticas en el diseño y aplicación del instrumento

Un aspecto central en el diseño y ejecución de este estudio fue el compromiso con los principios éticos que regulan la investigación con participación humana. En todas las etapas del proceso se procuró resguardar la dignidad, autonomía y privacidad de los participantes.

La encuesta incluyó una sección de consentimiento informado explícito, aclarando que la participación era completamente voluntaria, anónima, y que los datos serían utilizados únicamente con fines académicos. Se evitó la inclusión

de preguntas sensibles o invasivas. El lenguaje fue neutral, inclusivo y adaptado al público objetivo, permitiendo que el encuestado se posicionara libremente.

En el tratamiento de los datos, se aplicaron criterios de confidencialidad y protección de la información. Los archivos fueron anonimizados y almacenados en plataformas seguras, garantizando que ninguna persona pudiera ser identificada. Los resultados fueron presentados exclusivamente de forma agregada.


Se destaca el valor ético del propio proceso metodológico. Al someter el instrumento a un piloto riguroso y al incorporar la retroalimentación crítica de los estudiantes, el equipo de investigación promovió una relación horizontal entre el investigador y los participantes.

3.6.4. Conclusión sobre robustez metodológica

Este capítulo metodológico ha permitido no solo justificar la validez del instrumento aplicado, sino también evidenciar la solidez del proceso investigativo que lo sustenta. Se logró construir un instrumento confiable, sensible, éticamente responsable y metodológicamente defendible para estudiar la irrupción de la IAG en el ámbito universitario.

Los análisis realizados permiten afirmar que el cuestionario definitivo cumple con los criterios necesarios para ser considerado una herramienta válida en estudios educativos contemporáneos. Su diseño modular, su lenguaje accesible y su enfoque equilibrado lo hacen aplicable en diversas instituciones y adaptable a futuros contextos.

Además, el enfoque metodológico seguido constituye un modelo replicable para el diseño de instrumentos en temas de frontera tecnológica y educativa. Con ello, se cierra un capítulo que no solo respalda los hallazgos empíricos del estudio, sino que también establece una herramienta robusta y replicable para futuras investigaciones académicas.



CAPITULO 04

CARACTERIZACIÓN DE LA MUESTRA DE ESTUDIO

Caracterización de la muestra de estudio

4.1. Perfil del estudiante universitario en la era de la IA

La irrupción de la IA generativa en la educación superior constituye un fenómeno de profunda trascendencia, cuyas implicaciones apenas comienzan a comprenderse. Para analizar con rigor las percepciones, actitudes y patrones de uso de estas tecnologías entre el estudiantado, es imperativo iniciar con una caracterización exhaustiva de la población objeto de estudio. Este capítulo se dedica precisamente a delinear el perfil de los participantes, estableciendo el contexto demográfico, académico y tecnológico indispensable para la correcta interpretación de los hallazgos que se expondrán posteriormente. La validez y generalización de cualquier conclusión dependen intrínsecamente de la composición de la muestra; por tanto, un análisis detallado de sus características no es un mero preámbulo, sino un pilar fundamental de la investigación cuantitativa.

El presente capítulo tiene como objetivo principal presentar un retrato multidimensional de la muestra, compuesta por 474 estudiantes universitarios que respondieron al instrumento de recolección de datos. La estructura del capítulo se organiza en dos ejes analíticos principales. En primer lugar, se abordará el perfil sociodemográfico, examinando variables estructurales clave como el género, la edad y el nivel académico de los participantes. Esta sección busca responder a la pregunta: ¿quiénes son los estudiantes que conforman la muestra? En segundo lugar, se explorará el perfil tecnológico y de uso, centrado en la experiencia previa de los estudiantes con las herramientas de IA generativa. Se analizarán las plataformas específicas que han utilizado y, de manera crucial, la frecuencia con la que integran estas tecnologías en sus actividades académicas. Este segundo eje responde a la pregunta: ¿cómo y con qué intensidad interactúan estos estudiantes con la IA?

Al final del capítulo, se ofrecerá una síntesis que consolida los hallazgos descriptivos para construir un "perfil tipo" del estudiante participante. Esta caracterización servirá como un marco de referencia esencial para contextualizar

el análisis inferencial posterior, permitiendo que las percepciones sobre beneficios, riesgos y actitudes hacia la IA sean comprendidas no como fenómenos abstractos, sino como las voces de un colectivo específico de jóvenes inmersos en el ecosistema digital del siglo XXI.

4.2. Perfil sociodemográfico de los participantes

El análisis de las variables sociodemográficas constituye el primer paso para comprender la estructura de la muestra. Los datos revelan un colectivo predominantemente joven y con una distribución relativamente homogénea en términos de género y avance académico, características que se detallan a continuación.

4.2.1. Composición por género


La distribución de la muestra según el género de los participantes exhibe un equilibrio notable, aunque con una ligera predominancia del género femenino. Como se detalla en la Tabla 3 y se visualiza en la Figura 1, el 55.3% de los encuestados se identificaron como mujeres, mientras que el 43.2% se identificaron como hombres. Esta composición es consistente con las tendencias demográficas observadas en numerosas instituciones de educación superior a nivel global.

Tabla 3

Distribución de frecuencias y porcentajes por género

Género	Frecuencia (n)	Porcentaje (%)
Femenino	262	55.3
Masculino	205	43.2
Prefiere no decirlo	4	0.8
No binario	3	0.6
Total	474	100.0

Nota: La tabla desglosa las frecuencias absolutas (n) y relativas (%), confirmando una muestra equilibrada, fundamental para análisis comparativos sin sesgos de participación significativos (Autores, 2025).


Figura 1*Distribución por género de los participantes*

Nota: El gráfico de barras ilustra la composición de la muestra, destacando una participación mayoritariamente femenina. Las categorías no tradicionales, aunque minoritarias, reflejan la diversidad del estudiantado actual (Autores, 2025).

Es de particular interés la inclusión de categorías de identidad de género no binarias, que, si bien representan una fracción minoritaria de la muestra (0.8% optó por "Prefiere no decirlo" y 0.6% se identificó como "No binario"), son cruciales para una investigación inclusiva. Desde una perspectiva analítica, la distribución relativamente pareja entre los dos grupos mayoritarios proporciona una base sólida para los análisis comparativos que se realizarán en el capítulo posterior, permitiendo explorar posibles diferencias en la percepción y uso de la IA sin un sesgo de género pronunciado.

4.2.2. Distribución etaria de la muestra

El perfil etario de los participantes confirma que la muestra está compuesta en su gran mayoría por estudiantes pertenecientes al grupo demográfico de jóvenes adultos, comúnmente asociados a la "Generación Z". Esta generación, caracterizada por haber crecido íntegramente en un entorno digitalizado, constituye el núcleo de la población universitaria actual. Los datos, presentados en la Figura 2, son elocuentes: una mayoría abrumadora de dos tercios de los encuestados (66.5%) se encuentra en el rango de 18 a 21 años.

Figura 2*Distribución por rango de edad de los participantes*

Nota: La visualización muestra una fuerte concentración de participantes en el rango de edad universitario tradicional, sugiriendo que los hallazgos son especialmente representativos de la población de pregrado joven (Autores, 2025).


Este grupo principal es seguido por un 20.7% de estudiantes en el segmento de 22 a 25 años. Los grupos de edad en los extremos son minoritarios: un 5.5% corresponde a estudiantes menores de 18 años, mientras que los segmentos de 26 a 30 años (5.1%) y más de 30 años (2.3%) son menos representativos. La marcada concentración de la muestra en el grupo de nativos digitales es una variable contextual de suma importancia. Implica que las actitudes y comportamientos observados hacia la IA generativa provienen de individuos con una alta familiaridad innata con la tecnología, lo que podría traducirse en una mayor facilidad de adopción.

4.2.3. Nivel académico de los encuestados

Un hallazgo de gran relevancia para la robustez del estudio es la distribución equilibrada de los participantes a lo largo de su ciclo de formación universitaria. Como se puede observar en la Figura 3, la muestra incluye una representación significativa de estudiantes de todos los niveles académicos, evitando una sobre-representación que pudiera sesgar los resultados.

Figura 3

Distribución por año de estudio de los participantes



Nota: Este gráfico evidencia una distribución equitativa de los participantes a lo largo de su carrera. La inclusión de todos los niveles académicos fortalece la validez del estudio (Autores, 2025).

La distribución se desglosa de la siguiente manera: un 31.4% de los participantes cursan su Primer Año, seguidos de cerca por los estudiantes de Segundo Año (24.5%), Tercer Año (23.6%), y aquellos en su Cuarto Año o Superior (20.5%). La ausencia de grandes disparidades entre estos grupos es una fortaleza metodológica clave, ya que permite que los resultados ofrezcan una visión panorámica y transversal. Esta heterogeneidad habilita la posibilidad de realizar análisis comparativos robustos para investigar si la percepción y el uso de la IA se modifican a medida que aumenta la madurez académica.

4.2.4. Área de estudio de los participantes

El análisis de la distribución de la muestra por área de conocimiento revela una notable heterogeneidad, aunque con una concentración en ciertos campos. Como se detalla en la Tabla 4 y se visualiza en la Figura 4, el grupo más numeroso proviene del macrocampo de Ciencias Sociales, Negocios y Derecho, constituyendo un 41.1% del total. Este hallazgo es significativo, pues indica que la interacción con la IA está profundamente arraigada en disciplinas donde la redacción y el análisis documental son actividades centrales.

Tabla 4


Distribución de frecuencias y porcentajes por área de estudio

Área de Estudio	Frecuencia (n)	Porcentaje (%)
Ciencias Sociales, Negocios y Derecho	195	41.1
Ingeniería, Fabricación y Construcción	113	23.8
Ciencias (Naturales, Físicas, Informática)	57	12.0
Salud y Bienestar	53	11.2
Humanidades y Artes	43	9.1
Agricultura, Silvicultura y Veterinaria	8	1.7
Servicios	4	0.8
Educación	1	0.2
Total	474	100.0

Nota: La tabla desglosa la composición disciplinar de la muestra. La fuerte presencia de ciencias sociales e ingeniería sugiere que la adopción de la IA es un fenómeno transversal (Autores, 2025).

Figura 4

Distribución por área de estudio



Nota: El gráfico de barras muestra la diversidad disciplinar de la muestra. La prevalencia de las ciencias sociales y la ingeniería sugiere una adopción transversal de la IA (Autores, 2025).

El segundo grupo más grande corresponde a Ingeniería, Fabricación y Construcción, con un 23.8%. Más allá de estos dos grupos mayoritarios, el estudio cuenta con una participación significativa de estudiantes de Ciencias (12.0%), Salud y Bienestar (11.2%) y Humanidades y Artes (9.1%). Esta distribución diversa asegura que los resultados reflejen una perspectiva multidisciplinar, sugiriendo que la IA generativa se ha consolidado como una herramienta transversal en la educación superior.

4.3. Perfil tecnológico: Interacción con la IA Generativa


Habiendo delineado el perfil sociodemográfico, el análisis se centra ahora en la interacción directa de los estudiantes con las herramientas de IA generativa. Esta sección cuantifica las plataformas preferidas y la intensidad con la que se integran en las prácticas académicas.

4.3.1.Ecosistema de herramientas: La hegemonía de ChatGPT

El panorama de herramientas de IA generativa utilizadas por los estudiantes se caracteriza por una marcada hegemonía de una única plataforma. Como se muestra en la Figura 5, ChatGPT se erige como la herramienta dominante, acumulando un total de 435 menciones. Esta cifra supera en más del doble a su competidor más cercano, lo que indica un nivel de penetración extraordinario.

Figura 5

Herramientas de IA Generativa más utilizadas



Nota: La figura destaca la hegemonía de ChatGPT en el ecosistema de herramientas. La marcada diferencia en frecuencia de uso resalta una alta concentración del mercado (Autores, 2025).


El ecosistema se estructura en torno a un "top 3" claramente definido. Tras el líder indiscutible, se encuentran Gemini (190 menciones) y Copilot (90 menciones). Juntas, estas tres plataformas concentran la vasta mayoría de las interacciones. Este patrón de uso sugiere que la percepción general de los estudiantes sobre las capacidades y limitaciones de la IA podría estar fuertemente condicionada por su experiencia casi exclusiva con la arquitectura de ChatGPT.

4.3.2.Frecuencia de integración en la vida académica

El análisis de la frecuencia de uso indica que estas herramientas se han convertido en un recurso regular para la mayoría, superando la fase de uso meramente exploratorio. Los resultados, visualizados en la Figura 6, muestran que el patrón más extendido no es diario, sino periódico.

Figura 6

Frecuencia de uso de herramientas de IA Generativa



Nota: El gráfico ilustra que el uso de la IA es un hábito regular y no esporádico. La mayoría de los estudiantes integra estas herramientas en su rutina académica al menos mensualmente (Autores, 2025).

El grupo más grande de estudiantes, un 30.4%, reporta utilizar estas herramientas "Varias veces al mes". Le sigue de cerca un 28.7% que aumenta la frecuencia a "Varias veces a la semana". Sumando las categorías de mayor intensidad, se obtiene un dato revelador: el 56.6% de la muestra utiliza la IA generativa con una periodicidad de al menos una vez por semana. En el otro extremo, un 13.1% de los encuestados afirma utilizar estas herramientas "Nunca o Rara vez", denotando la existencia de un segmento que se mantiene al margen de esta tendencia.

4.4. Síntesis del perfil del participante


El análisis descriptivo permite construir un perfil detallado del participante típico de este estudio. Dicho perfil es fundamental para contextualizar los análisis actitudinales y perceptuales que constituyen el núcleo de la investigación.

El participante arquetípico es una estudiante mujer (55.3%), joven, con una edad comprendida entre los 18 y 21 años (66.5%), que se encuentra en las etapas iniciales o intermedias de su formación. Esta caracterización la sitúa firmemente

dentro de la cohorte de los "nativos digitales", una generación para la cual la aproximación a las nuevas herramientas digitales se presume natural e intuitiva.

Desde la perspectiva de su comportamiento tecnológico, esta estudiante ha integrado la IA generativa en su repertorio de herramientas académicas de manera consolidada. Su plataforma de elección es, de forma casi exclusiva, ChatGPT. Su patrón de uso no es compulsivo ni esporádico, sino más bien funcional y regular: recurre a la herramienta varias veces al mes o a la semana, sugiriendo un uso instrumental y orientado a tareas específicas.

La solidez de la muestra, con una representación equilibrada entre géneros y a lo largo de los distintos años de estudio, confiere una notable robustez a los hallazgos. Indica que el fenómeno descrito no se limita a un nicho, sino que es transversal a la experiencia universitaria. Es con este perfil en mente, una joven estudiante, nativa digital, usuaria regular de ChatGPT, que se debe abordar la interpretación de los resultados del Capítulo 5. Sus opiniones, percepciones de riesgo y actitudes están moldeadas por esta realidad demográfica y de uso.



CAPITULO 05

ANÁLISIS DE RESULTADOS Y HALLAZGOS ESTADÍSTICOS

Análisis de resultados y hallazgos estadísticos

5.1. De los datos a las percepciones

Tras haber caracterizado en detalle a la población estudiantil en el capítulo anterior, el presente capítulo se adentra en el núcleo de la investigación: el análisis de sus percepciones, actitudes y valoraciones en torno al uso de la IA generativa. El objetivo es trascender la descripción demográfica para cuantificar y explorar la compleja red de opiniones que los estudiantes han tejido en torno a estas tecnologías. Este capítulo se erige como el pilar analítico del libro, donde los datos brutos se transforman en evidencia estadística para responder a las preguntas de investigación.

La estructura ha sido diseñada para guiar al lector en un recorrido lógico, de lo descriptivo a lo inferencial. En la primera sección, se realizará un análisis exhaustivo de las respuestas a los ítems del cuestionario, agrupados en cuatro constructos temáticos: Percepción de Beneficios (P), Preocupación por Riesgos (C), Actitud hacia la Integración Institucional (A) y Visión a Futuro (F). Mediante estadísticos de tendencia central y dispersión, se identificarán las opiniones dominantes y las áreas de mayor consenso o controversia.

Posteriormente, el análisis avanzará hacia la estadística inferencial para descubrir relaciones subyacentes y diferencias significativas entre grupos. Se explorarán las correlaciones (Pearson) entre los constructos y se aplicarán pruebas de diferencia de grupos (Prueba T de Student y ANOVA) para investigar si variables como el género o el año de estudio influyen en las percepciones. El capítulo culminará con una discusión de los hallazgos clave, sentando las bases para las conclusiones y recomendaciones finales.

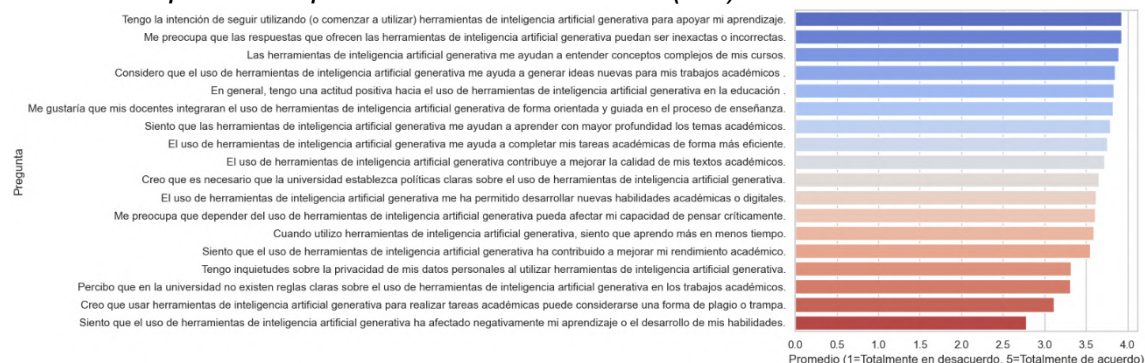
5.2. Análisis descriptivo de las percepciones estudiantiles por constructo

El primer paso para comprender la visión del estudiantado es analizar la tendencia general de sus respuestas. Para ello, se examinaron las medias (M) y

desviaciones estándar (DE) de cada ítem valorado en una escala Likert de 1 ("Totalmente en desacuerdo") a 5 ("Totalmente de acuerdo"). Un valor medio superior a 3.0 indica una tendencia hacia el acuerdo. La desviación estándar, por su parte, informa sobre el grado de consenso. La Figura 7 ofrece una visión panorámica de estos resultados.

Figura 7

Valoración promedio por ítem en escala Likert (1-5)



Nota: El gráfico de barras visualiza la media de cada ítem, permitiendo una rápida identificación de las percepciones dominantes. Las barras más largas representan un mayor grado de acuerdo general (Autores, 2025).

5.2.1. Constructo de beneficios y utilidad percibida (P)

Este bloque de ítems se diseñó para medir hasta qué punto los estudiantes perciben la IA generativa como una herramienta valiosa para su proceso de aprendizaje. Los resultados, presentados en la Tabla 5, indican una valoración abrumadoramente positiva, con todas las medias situadas muy por encima del punto neutral de la escala.

Tabla 5

Estadísticos descriptivos de las percepciones

Ítem	M	DE
Tengo la intención de seguir utilizando (o comenzar a utilizar) IA para apoyar mi aprendizaje.	3.93	0.91
Me preocupa que las respuestas que ofrecen las herramientas de IA puedan ser inexactas o incorrectas.	3.93	1.01
Las herramientas de IA me ayudan a entender conceptos complejos de mis cursos.	3.89	0.98
Considero que el uso de IA me ayuda a generar ideas nuevas para mis trabajos académicos.	3.85	0.95
En general, tengo una actitud positiva hacia el uso de herramientas de IA en la educación.	3.83	0.90
Me gustaría que mis docentes integraran el uso de IA de forma orientada y guiada.	3.82	1.00
Siento que las herramientas de IA me ayudan a aprender con mayor profundidad los temas académicos.	3.79	0.94
El uso de IA me ayuda a completar mis tareas académicas de forma más eficiente.	3.75	0.92
El uso de IA contribuye a mejorar la calidad de mis textos académicos.	3.72	0.94

Creo que es necesario que la universidad establezca políticas claras sobre el uso de la IA.	3.65	0.95
El uso de IA me ha permitido desarrollar nuevas habilidades académicas o digitales.	3.62	0.96
Me preocupa que depender de la IA pueda afectar mi capacidad de pensar críticamente.	3.61	1.17
Cuando utilizo IA, siento que aprendo más en menos tiempo.	3.59	0.98
Siento que el uso de IA ha contribuido a mejorar mi rendimiento académico.	3.55	0.98
Tengo inquietudes sobre la privacidad de mis datos personales al utilizar herramientas de IA.	3.32	1.08
Percibo que en la universidad no existen reglas claras sobre el uso de la IA.	3.31	1.06
Creo que usar IA para realizar tareas académicas puede considerarse una forma de plagio o trampa.	3.11	1.09
Siento que el uso de IA ha afectado negativamente mi aprendizaje o el desarrollo de mis habilidades.	2.78	1.13

Nota: La tabla presenta las medias (M) y las desviaciones estándar (DE) para cada ítem. Las respuestas se midieron en una escala Likert de 1 (Totalmente en desacuerdo) a 5 (Totalmente de acuerdo) (Autores, 2025).

La afirmación que goza de mayor acuerdo es la relativa a la capacidad de la IA para "ayudar a entender conceptos complejos" ($M=3.89$, $DE=0.98$). Este hallazgo sugiere que los estudiantes no ven estas herramientas como meros buscadores de información, sino como aliados cognitivos. Le sigue de cerca la percepción de que la IA "ayuda a generar ideas nuevas" ($M=3.85$, $DE=0.95$), lo que la posiciona como un catalizador de la creatividad.

La utilidad de la IA para el aprendizaje profundo y la eficiencia también es altamente valorada. Los estudiantes sienten que estas herramientas les "ayudan a aprender con mayor profundidad" ($M=3.79$, $DE=0.94$) y a "completar tareas de forma más eficiente" ($M=3.75$, $DE=0.92$). En conjunto, este bloque dibuja un panorama en el que los estudiantes han adoptado la IA generativa como un instrumento polivalente que impacta positivamente en la comprensión, la ideación, la eficiencia y la calidad de su trabajo académico.

5.2.2. Constructo de riesgos y preocupaciones (C)

Mientras que el primer bloque reveló un optimismo pragmático, este segundo constructo muestra el reverso: una conciencia crítica y una notable preocupación por las limitaciones y los dilemas éticos de la IA. Lejos de una adopción acrítica, los estudiantes demuestran una sofisticada comprensión de los riesgos inherentes.

Paradójicamente, la preocupación que genera mayor acuerdo es también la que obtiene la puntuación media más alta de todo el cuestionario: "Me preocupa que

las respuestas que ofrecen puedan ser inexactas o incorrectas" ($M=3.93$, $DE=1.01$). Este dato es fundamental, pues indica que la mayoría de los usuarios son conscientes de las limitaciones de fiabilidad de los modelos y no aceptan sus resultados como una verdad absoluta.

Otra preocupación significativa es el riesgo de la dependencia intelectual, reflejada en el acuerdo con la idea de que "depender del uso de herramientas de IA pueda afectar mi capacidad de pensar críticamente" ($M=3.61$, $DE=1.17$). Las inquietudes sobre la privacidad de los datos personales ($M=3.32$, $DE=1.08$) también superan el punto medio.

En el terreno de la ética académica, la percepción es más ambivalente. La afirmación de que usar IA "puede considerarse una forma de plagio o trampa" obtiene una media de $M=3.11$, un valor que, al estar apenas por encima del punto neutral, denota una profunda incertidumbre y la ausencia de un consenso claro. Finalmente, es revelador que la afirmación "Siento que el uso de IA ha afectado negativamente mi aprendizaje" sea la que obtiene la puntuación más baja del cuestionario ($M=2.78$, $DE=1.13$), lo que sugiere que, a pesar de las preocupaciones teóricas, la experiencia práctica de los estudiantes no es, en general, negativa.

5.2.3. Constructo de actitud y postura institucional (A)

Este bloque explora la actitud general de los estudiantes hacia la integración de la IA y su percepción sobre el rol que la institución debería jugar. Los resultados evidencian un claro llamado a la acción.

La actitud general es positiva, como lo refleja el alto acuerdo con la afirmación "En general, tengo una actitud positiva hacia el uso de herramientas de IA en la educación" ($M=3.83$, $DE=0.90$). Esta predisposición favorable se traduce en un deseo de integración curricular, ya que los estudiantes concuerdan mayoritariamente en que les "gustaría que mis docentes integraran el uso de IA de forma orientada y guiada" ($M=3.82$, $DE=1.00$).

La necesidad de un marco normativo es otro tema central. Los estudiantes están de acuerdo con que "es necesario que la universidad establezca políticas claras" ($M=3.65$, $DE=0.95$). Este dato, junto a la percepción de que actualmente "no

existen reglas claras" ($M=3.31$, $DE=1.06$), configura una demanda explícita hacia la administración universitaria para que ofrezca orientación y seguridad.

5.2.4. Constructo de visión a futuro (F)

Finalmente, este constructo evalúa las intenciones y expectativas de los estudiantes respecto al rol futuro de la IA. Las respuestas reflejan un fuerte optimismo y una clara intención de continuar utilizando estas herramientas.

La afirmación con la valoración más alta de este bloque es la que mide la intención de uso futuro: "Tengo la intención de seguir utilizando (o comenzar a utilizar) IA para apoyar mi aprendizaje" ($M=3.93$, $DE=0.91$). Un promedio tan elevado indica que la adopción de estas herramientas no es una moda pasajera, sino un cambio de hábito que los estudiantes planean mantener a largo plazo.

5.3. Análisis inferencial: Explorando relaciones y diferencias


Tras describir las tendencias generales, el análisis inferencial busca profundizar en la estructura de estas percepciones. Se investigan las relaciones entre los distintos constructos y se explora si existen diferencias significativas en las opiniones de diversos subgrupos.

5.3.1. Correlaciones entre las dimensiones de la percepción

Para examinar la relación entre los cuatro constructos principales (Beneficios, Riesgos, Actitud y Futuro), se calcularon los coeficientes de correlación de Pearson (r). Los resultados, visualizados en la Figura 8, revelan una red de asociaciones de interés.

Figura 8

Correlaciones de Pearson entre los constructos



Nota: El mapa de calor representa visualmente la matriz de correlación. Los colores más intensos indican las relaciones positivas más fuertes entre los constructos (Autores, 2025).

La correlación más intensa se observa entre la Percepción de Beneficios (P) y la Visión a Futuro (F) ($r=.672$). Esta fuerte asociación positiva es lógicamente consistente: cuanto más un estudiante percibe que la IA es útil, más positiva es su visión sobre el impacto futuro y mayor es su intención de seguir utilizándola.

De igual manera, se encontraron correlaciones positivas y fuertes entre la Percepción de Beneficios (P) y la Actitud (A) ($r=.589$), y entre la Actitud (A) y la Visión a Futuro (F) ($r=.618$). Juntas, estas tres asociaciones forman un "triángulo virtuoso": los beneficios percibidos alimentan una actitud positiva, y ambos se proyectan en una visión optimista del futuro.

Quizás el hallazgo más revelador es la débil asociación del constructo de Riesgos (C) con todos los demás. La correlación entre Riesgos y Beneficios es prácticamente nula ($r=.105$). Esto desmonta la idea de que los estudiantes se dividen en "pro-IA" y "anti-IA". Por el contrario, los datos sugieren que las dos percepciones son constructos ortogonales; un estudiante puede, simultáneamente, valorar enormemente la utilidad de la IA y estar profundamente preocupado por sus limitaciones. Esta coexistencia define un perfil de usuario "crítico-pragmático".

5.3.2. Análisis de diferencias entre grupos

Se investigó si las percepciones varían en función de características sociodemográficas clave mediante una Prueba T de Student y un análisis de varianza (ANOVA).

- a) Percepción de riesgos por género (Prueba T-Student). Se planteó si existen diferencias estadísticamente significativas en la percepción de riesgos entre estudiantes hombres y mujeres. Los resultados de la Prueba T no mostraron una diferencia significativa ($t = -1.5894$, $p = .1126$). Al ser el valor p superior al nivel de significancia ($\alpha = .05$), se concluye que no hay evidencia estadística para afirmar que ambos grupos en esta muestra difieran en su nivel de preocupación.
- b) Percepción de beneficios por año de estudio (ANOVA). Se investigó si la percepción de los beneficios de la IA varía a medida que los estudiantes avanzan en su carrera. El análisis de varianza (ANOVA) no arrojó un resultado estadísticamente significativo ($F = 0.6591$, $p = .5775$). El valor p excede el umbral de $.05$, lo que indica que no existen diferencias significativas en la valoración de la utilidad de la IA entre los estudiantes de distintos años.

5.4. Tendencias dominantes e interpretación de los resultados

La síntesis de los hallazgos descriptivos e inferenciales permite identificar las tendencias dominantes y discutir sus implicaciones. De los datos emergen tres narrativas principales que configuran la relación del estudiantado con la IA generativa.

La primera tendencia es el "Pragmatismo Crítico". Los estudiantes no son ni tecnófilos ingenuos ni tecnófobos. Demuestran un claro pragmatismo al integrar la IA masivamente en su flujo de trabajo. Sin embargo, este pragmatismo está balanceado por una aguda conciencia crítica, siendo la mayor preocupación la falta de fiabilidad de las herramientas. La independencia estadística entre la percepción de beneficios y riesgos es la prueba fehaciente de esta dualidad.

La segunda tendencia es el "Consenso Actitudinal Transversal". Los análisis inferenciales son claros: las percepciones sobre riesgos y beneficios no varían significativamente en función del género o del año de estudio. La experiencia con la IA parece ser notablemente homogénea. Esto sugiere que la cultura digital compartida por esta generación es un factor más influyente que las variables demográficas tradicionales.

Finalmente, la tercera tendencia es el "Llamado a la Institucionalización". Los estudiantes no utilizan la IA en la clandestinidad; por el contrario, su deseo es que la universidad y sus docentes se involucren. Existe una demanda explícita de políticas institucionales claras y de una integración pedagógica guiada. Este hallazgo representa una oportunidad y una responsabilidad para las instituciones de educación superior.

En suma, los resultados presentan un cuadro complejo y matizado. El estudiantado ha abrazado la IA generativa por su utilidad demostrada, pero mantiene una distancia crítica que le permite navegar sus riesgos. Su experiencia es notablemente uniforme y su mensaje a la academia es unívoco: es hora de dialogar, regular e integrar.



CAPITULO 06

APLICACIÓN DE TÉCNICAS DE MACHINE LEARNING

Aplicación de técnicas de Machine Learning

6.1. De la descripción a la predicción y el descubrimiento de patrones

Los capítulos precedentes de esta obra han sentado las bases para una comprensión robusta del fenómeno de la IA generativa en el contexto universitario. Se ha caracterizado a la población estudiantil y se han analizado sus percepciones a través de estadísticos descriptivos e inferenciales. Si bien estos análisis son indispensables, la complejidad inherente a las interacciones humano-tecnología demanda un enfoque que trascienda la descripción para adentrarse en los dominios del descubrimiento de patrones y la predicción.

Este capítulo se dedica precisamente a esta tarea, aplicando un conjunto de algoritmos de aprendizaje automático (machine learning o ML) para desvelar estructuras latentes en los datos y construir modelos con capacidad predictiva. El objetivo es, por tanto, elevar el nivel de análisis, pasando de responder "¿qué piensan los estudiantes?" a responder "¿existen arquetipos de estudiantes?" y "¿qué factores permiten anticipar sus futuras intenciones?".

El andamiaje metodológico de este capítulo se articula en torno a los dos paradigmas fundamentales del machine learning. La primera parte del análisis se centrará en los modelos no supervisados. A través del algoritmo de clustering K-Means y el Análisis de Componentes Principales (PCA), se abordará una tarea exploratoria: la segmentación de la muestra. Estos algoritmos tienen la capacidad de identificar si existen grupos naturales de estudiantes que comparten patrones de percepción consistentes, sin ninguna etiqueta predefinida. Este enfoque permitirá descubrir si la aparente homogeneidad de la población esconde una diversidad de perfiles actitudinales diferenciados.

La segunda parte del capítulo se dedicará a los modelos supervisados de clasificación, con un objetivo eminentemente predictivo. Se construirá y evaluará una serie de modelos (Regresión Logística, Árbol de Decisión y Random Forest) con la finalidad de predecir una variable de alto interés: la intención de un estudiante de continuar utilizando la IA en el futuro. Utilizando las percepciones

sobre beneficios y riesgos como variables predictoras, se buscará no solo construir un modelo preciso, sino también comprender qué factores son los más influyentes en la consolidación de este hábito.

A través de la aplicación de estas técnicas, este capítulo aspira a ofrecer un valor añadido significativo. La segmentación de perfiles puede informar el diseño de intervenciones pedagógicas más personalizadas y eficaces. Por su parte, la identificación de los predictores de la adopción a largo plazo puede guiar el desarrollo de políticas institucionales que fomenten un uso de la IA innovador, crítico y ético.

6.2. Preparación del dataset para el modelado

La validez de cualquier modelo de machine learning depende de la calidad y el formato de los datos de entrada (J. Li et al., 2024). Por ello, antes de proceder a la implementación de los algoritmos, fue necesario llevar a cabo un proceso de preprocesamiento meticuloso del conjunto de datos (Acosta-Enriquez et al., 2024). Esta fase, aunque técnica, es conceptualmente crucial, pues asegura que los modelos operen sobre una base de datos coherente, estandarizada y matemáticamente interpretable (Borges et al., 2024).

El primer paso consistió en la selección de variables predictoras (features) (Huang & Mizumoto, 2024). Se decidió incluir un conjunto amplio de variables para capturar la máxima información posible, incluyendo todas las variables sociodemográficas, las relativas a la frecuencia de uso y la totalidad de los ítems valorados en la escala Likert (Huang & Mizumoto, 2024). Se excluyeron deliberadamente las columnas con respuestas de texto abierto, ya que su análisis requiere técnicas de Procesamiento de Lenguaje Natural (NLP) que exceden el alcance de este capítulo (An et al., 2025; El-Bayaa et al., 2025).

Un desafío central en la preparación de datos de encuestas es el tratamiento de las variables categóricas (como Género o Área de Estudio). Para que los algoritmos pudieran procesar esta información sin realizar asunciones erróneas, se aplicó la técnica de One-Hot Encoding (Jiang et al., 2025). Este procedimiento transforma una columna categórica con n categorías en n nuevas columnas

binarias (con valores 0 o 1), permitiendo que el modelo considere cada opción de forma independiente (Đerić et al., 2025).

Paralelamente, para evitar que las variables con rangos numéricos más amplios dominaran el análisis, todos los ítems de la escala Likert fueron sometidos a un proceso de estandarización mediante StandardScaler (Chen et al., 2025). Esta técnica transforma cada variable para que su distribución tenga una media de 0 y una desviación estándar de 1, asegurando que cada una contribuya de manera equitativa al modelo (Q. Wu et al., 2025).

Para el desarrollo de los modelos supervisados, el conjunto de datos se particionó aleatoriamente en un conjunto de entrenamiento (70% de los datos) y un conjunto de prueba (30% restante). Esta es una práctica canónica en machine learning para evaluar la capacidad de generalización del modelo (Rudolph et al., 2024). Los algoritmos "aprenden" los patrones a partir de los datos de entrenamiento y su rendimiento se evalúa en el conjunto de prueba, que contiene datos que el modelo no ha visto previamente, un mecanismo fundamental contra el sobreajuste (overfitting).

6.3. Modelos no supervisados: La segmentación de perfiles estudiantiles

El primer objetivo del análisis de machine learning fue exploratorio: determinar si la población estudiantil se puede segmentar en subgrupos con patrones de percepción distintivos (Acosta-Enriquez et al., 2024). Para ello, se utilizó el algoritmo de clustering K-Means.

6.3.1. Determinación empírica del número óptimo de perfiles (K)


Una decisión crítica en el clustering es predefinir el número de grupos (K) (Barakat, 2025; Iulian et al., 2024). Para evitar una elección arbitraria, se empleó la Técnica del Codo (Elbow Method). Este procedimiento consiste en ejecutar el algoritmo K-Means para un rango de valores de K y calcular para cada uno la "inercia", una medida de cuán compactos son los clústeres. Al graficar la inercia

en función de K, se busca el "codo" de la curva, el punto donde agregar un nuevo clúster deja de producir una disminución significativa en la inercia.

El resultado se presenta en la Figura 9. La curva muestra una caída abrupta de la inercia hasta K=3, punto a partir del cual la pendiente se suaviza considerablemente. Este punto de inflexión sugiere que segmentar a la población en tres perfiles representa el equilibrio más eficiente entre la simplicidad del modelo y su capacidad para capturar la estructura de los datos.

Figura 9

Técnica del codo para la determinación de K óptimo



Nota: El gráfico muestra la disminución de la inercia a medida que aumenta el número de clústeres (K). El "codo" en K=3 sugiere el punto óptimo de segmentación (Autores, 2025).

6.3.2. Caracterización e interpretación de los perfiles emergentes

Una vez ejecutado el algoritmo K-Means con K=3, se procedió a la fase interpretativa, analizando los centroides de cada clúster (Fischer et al., 2024). Un centroide representa la respuesta promedio de los miembros de ese grupo a cada ítem del cuestionario (Barus et al., 2025). La Tabla 6 presenta estos centroides, permitiendo una caracterización detallada de cada perfil.

Tabla 6

Perfiles de usuario según la respuesta promedio

Ítem	Perfil 0: El "Escéptico Mínimo"	Perfil 1: El "Pragmático Crítico"	Perfil 2: El "Tecno-Optimista Integrado"
Beneficios (P)			
P_Conc_2_1	2.71	3.94	4.70
P_Ideas_2_2	2.55	3.92	4.71
P_Calid_2_3	2.66	3.70	4.62
P_Aprend_2_4	2.62	3.80	4.70
P_Efic_2_5	2.67	3.80	4.50

Riesgos (C)			
C_Inexa_3_1	3.26	4.14	3.86
C_Plagio_3_2	3.10	3.34	2.47
C_Priv_3_3	3.04	3.55	2.88
C_Depend_3_4	3.33	3.94	2.91
C_Trab_3_5	2.91	3.36	3.47
Actitud (A)			
A_Acep_4_1	2.54	3.54	4.41
A_Integ_4_2	2.51	3.58	4.52
A_Polit_4_3	2.65	3.58	4.51
A_Etica_4_4	2.83	3.02	2.04
Futuro (F)			
F_Impac_5_1	2.59	3.90	4.64
F_Evol_5_2	2.59	3.90	4.61
F_Adop_5_3	2.99	3.71	4.01
F_Recom_5_4	2.73	3.98	4.73

Nota: La tabla presenta los centroides de cada clúster, que representan la respuesta promedio (en escala 1-5) de los miembros de cada perfil a los ítems del cuestionario (Autores, 2025).

A partir de los datos, se pueden delinear tres arquetipos estudiantiles:

- 1) Perfil 0: El "Escéptico Mínimo". Este grupo se define por una marcada falta de entusiasmo. Sus puntuaciones en el constructo de Beneficios (P) son las más bajas, situándose por debajo del punto neutral. Sin embargo, su nivel de Preocupación por los Riesgos (C) no es extremadamente alto. Este perfil no parece corresponder a un "detractor", sino más bien a un usuario periférico o indiferente.
- 2) Perfil 1: El "Pragmático Crítico". Este perfil encarna el concepto discutido en el capítulo anterior. Valoran muy positivamente los beneficios de la IA, pero simultáneamente, exhiben el nivel más elevado de preocupación por los riesgos (inexactitud de las respuestas y amenaza al pensamiento crítico). Corresponde al usuario informado y reflexivo que ha integrado la IA manteniendo una distancia crítica.
- 3) Perfil 2: El "Tecno-Optimista Integrado". En el extremo opuesto, este grupo muestra las puntuaciones más altas en todas las dimensiones positivas (beneficios, actitud y visión a futuro) y los niveles más bajos de preocupación por los riesgos, particularmente en las dimensiones éticas. Para estos estudiantes, la IA es un socio cognitivo fundamental, y tienden a minimizar sus desventajas.

6.3.3. Visualización de la segmentación mediante PCA


Para validar visualmente la separación de estos tres perfiles, se aplicó el Análisis de Componentes Principales (PCA) (Barakat, 2025). Esta técnica permite

proyectar los datos de un espacio de alta dimensionalidad a un espacio de dos dimensiones que captura la mayor parte de la varianza original (Iulian et al., 2024).

El resultado se muestra en la Figura 10. Cada punto representa a un estudiante, y su color indica el perfil al que fue asignado. Se observan tres "nubes" de puntos claramente diferenciadas, lo que confirma que los perfiles identificados son agrupaciones reales. Se aprecia cómo el "Tecno-Optimista" y el "Escéptico" ocupan posiciones antagónicas, mientras que el "Pragmático Crítico" se sitúa en una zona intermedia.

Figura 10

Visualización de los tres perfiles de usuario mediante PCA



Nota: Esta figura representa los tres perfiles de usuario en un espacio bidimensional reducido por PCA. La separación visual entre los grupos valida la cohesión interna de los clústeres (Autores, 2025).

6.4. Modelos Supervisados: Predicción de la adopción de la IA

Una vez identificados los perfiles, el análisis se desplazó hacia un objetivo predictivo: construir un modelo capaz de anticipar la intención de un estudiante de continuar utilizando la IA en el futuro (Balaskas et al., 2025; Cabero-Almenara et al., 2025).

6.4.1. Formulación del problema de clasificación

El primer paso fue operacionalizar la variable objetivo. Se seleccionó el ítem F_Recom_5_4 ("Tengo la intención de seguir utilizando...") como el indicador más directo de la adopción a largo plazo. La variable fue dicotomizada: las respuestas 4 ("De acuerdo") y 5 ("Totalmente de acuerdo") fueron etiquetadas como "Clase 1" (Alta Intención), mientras que las respuestas 1, 2 o 3 fueron etiquetadas como "Clase 0" (Baja o Media Intención). El desafío fue predecir la pertenencia de un estudiante a una de estas dos clases.

6.4.2. Desarrollo y evaluación comparativa de los modelos

Se entrenaron y evaluaron tres algoritmos: Regresión Logística, Árbol de Decisión y Random Forest (Smit et al., 2025). Su rendimiento se basó en métricas estándar como la Exactitud (Accuracy), Precisión (Precision), Recall y F1-Score. La Tabla 7 resume los resultados.

Tabla 7


Métricas de rendimiento de los modelos de clasificación

Modelo	Exactitud (Accuracy)	F1-Score (Ponderado)
Regresión Logística	0.8462	0.8417
Árbol de Decisión	0.8112	0.8120
Random Forest	0.8811	0.8740

Nota: Se comparan las métricas de rendimiento de los tres modelos. La Exactitud mide las predicciones correctas totales, mientras que el F1-Score ofrece una media balanceada entre precisión y recall (Autores 2025).


Los modelos dieron como resultado lo siguiente:

- a) Regresión Logística: Este modelo lineal sirvió como una sólida línea base, obteniendo una Exactitud del 84.6%. Su matriz de confusión (Figura 11) muestra que es particularmente eficaz para identificar a los estudiantes de la "Clase 1" (Alta Intención), aunque tiende a clasificar erróneamente a un número considerable de estudiantes escépticos.

Figura 11*Matriz de confusión para el modelo de Regresión Logística*

Nota: La matriz de confusión visualiza el rendimiento del modelo. La diagonal principal muestra el número de predicciones correctas para cada clase (Autores 2025).

- a) **Árbol de Decisión:** Este modelo, conocido por su alta interpretabilidad, obtuvo un rendimiento ligeramente inferior, con una Exactitud del 81.1%. Su matriz de confusión (Figura 12) muestra un rendimiento más equilibrado, pero a costa de una menor precisión general.

Figura 12*Matriz de confusión para el clasificador de Árbol de Decisión*


Nota: La matriz detalla los aciertos y errores del clasificador, permitiendo comparar su capacidad para identificar ambas clases de forma equilibrada (Autores 2025).

- a) **Random Forest:** Este modelo de ensamblaje demostró ser el más robusto, alcanzando la Exactitud más alta con un 88.1% y un F1-Score de 0.874. Su superioridad es evidente en la matriz de confusión (Figura 13), donde

mejora significativamente la precisión al identificar a los estudiantes con baja intención.

Figura 13

Matriz de confusión para el modelo Random Forest



Nota: Esta matriz corresponde al modelo con mejor rendimiento. El alto número en la diagonal confirma su superioridad para clasificar correctamente la intención de uso (Autores 2025).

Con base en su rendimiento superior, el modelo Random Forest fue seleccionado como el clasificador más adecuado para predecir la intención de uso futuro de la IA por parte de los estudiantes.

6.5. Valor predictivo y aplicaciones institucionales estratégicas

La aplicación de un doble enfoque de machine learning ha arrojado dos conjuntos de hallazgos de considerable valor estratégico. Primero, la evidencia del clustering demuestra que la población estudiantil no es un colectivo homogéneo, sino que coexisten al menos tres perfiles actitudinales robustos. Segundo, los resultados del modelado supervisado demuestran que es posible predecir con un alto grado de certeza (88.1%) la intención de un estudiante de consolidar el uso de la IA.

Estos hallazgos tienen implicaciones directas para las instituciones de educación superior. El conocimiento de estos perfiles permite evolucionar desde políticas genéricas hacia intervenciones pedagógicas y programas de alfabetización digital segmentados:

- Para los "Tecno-Optimistas", el enfoque debería centrarse en cultivar un escepticismo saludable, con talleres sobre análisis de sesgos algorítmicos y ética de datos.
- Para los "Pragmáticos Críticos", las intervenciones deberían validar sus preocupaciones y ofrecerles herramientas avanzadas para gestionarlas, como técnicas de verificación de información (fact-checking) y uso ético de la IA.
- Para los "Escépticos Mínimos", la estrategia debería ser de sensibilización y demostración, mostrando casos de uso de alto impacto en su área de estudio específica para reducir la barrera de la indiferencia.

Por otro lado, el modelo predictivo puede ser utilizado como una herramienta de diagnóstico institucional. Mediante un análisis de la "importancia de las variables" (feature importance), la universidad podría identificar qué percepciones son los "interruptores" cognitivos que más pesan en la decisión de adoptar la IA de forma sostenida. Intervenir sobre estos factores específicos podría ser una estrategia de alta eficiencia para cultivar una cultura de uso de la IA que sea innovadora, crítica y alineada con los valores académicos.

La aplicación de machine learning no solo ha confirmado tendencias, sino que ha proporcionado un mapa de la diversidad actitudinal del estudiantado y una brújula para la acción institucional, demostrando cómo la analítica de datos avanzada puede transformar la investigación educativa en inteligencia estratégica.



CAPITULO 07

DISCUSIÓN E IMPLICACIONES DE LOS HALLAZGOS

Discusión e implicaciones de los hallazgos

7.1. De los hallazgos a la interpretación

Los capítulos precedentes han desglosado de manera sistemática la compleja relación que el estudiantado universitario ha establecido con la IA generativa. Se ha trazado un perfil demográfico y tecnológico de la muestra, se han cuantificado sus percepciones a través de análisis descriptivos e inferenciales, y se han descubierto patrones latentes mediante técnicas de machine learning. Cada capítulo ha aportado una pieza indispensable del rompecabezas.

La tarea fundamental de este séptimo capítulo es ensamblar estas piezas para construir una imagen coherente, interpretar su significado en un contexto más amplio y discutir sus profundas implicaciones para el futuro de la educación superior. Este es el punto donde los datos se convierten en diálogo, y las estadísticas en estrategia.

Este capítulo se erige, por tanto, como el espacio de síntesis y reflexión crítica de la obra. Su propósito no es meramente resumir los resultados, sino trascenderlos, tejiendo una narrativa que conecte los hallazgos empíricos con los debates teóricos y las tensiones prácticas que definen este momento histórico. Se buscará responder a preguntas fundamentales: ¿Qué nos dice la coexistencia de un alto optimismo y una profunda preocupación sobre la madurez digital del estudiantado? ¿Cómo dialogan estos hallazgos con los modelos teóricos de adopción tecnológica? Y, de manera crucial, ¿qué hoja de ruta se puede trazar para que gestores, docentes y los propios estudiantes naveguen esta nueva realidad de una manera innovadora, ética y pedagógicamente enriquecedora?

Para abordar estas cuestiones, el capítulo se estructura en tres ejes principales. Primero, se realizará una interpretación cruzada de los hallazgos para consolidar el arquetipo del usuario "crítico-pragmático". Segundo, se pondrán estos hallazgos en diálogo con el marco teórico, evaluando cómo confirman o desafían los modelos existentes. Finalmente, se explorarán las implicaciones estratégicas

de la investigación, traduciendo la evidencia empírica en recomendaciones concretas para la política educativa y la práctica docente.

7.2. Síntesis de un fenómeno complejo

El hallazgo más consistente y transversal de esta investigación es la aparente paradoja que define la relación del estudiantado con la IA generativa (Acosta-Enriquez et al., 2024). Los análisis del Capítulo V revelaron una dualidad sorprendente: los estudiantes exhiben, de manera simultánea, una valoración abrumadoramente positiva de los beneficios de estas herramientas y una conciencia aguda y extendida de sus riesgos (Barus et al., 2025; Fischer et al., 2024).

No se trata de dos grupos de opinión enfrentados, entusiastas contra detractores, sino de una misma población que alberga ambas percepciones con notable intensidad (Gallent Torres et al., 2023). El ítem con mayor acuerdo en todo el cuestionario fue, precisamente, la "preocupación por respuestas inexactas" ($M=3.93$), seguido de cerca por la "intención de seguir utilizando IA" ($M=3.93$). Esta coexistencia de escepticismo y adopción es la piedra angular para comprender al usuario universitario actual (Sallam et al., 2024).

El análisis de machine learning del Capítulo VI no solo confirmó esta dualidad, sino que le dio estructura y profundidad. La segmentación mediante el algoritmo K-Means demostró que esta narrativa no es una simple media estadística, sino que corresponde al perfil mayoritario y central de la población: el "Pragmático Crítico".

Este arquetipo, que representa al usuario informado y reflexivo, ha integrado la IA en su rutina académica por su innegable valor instrumental, para entender conceptos complejos, generar ideas y mejorar la eficiencia, pero lo hace manteniendo una distancia crítica, plenamente consciente de las limitaciones de fiabilidad y de los dilemas éticos que conlleva (Acosta-Enriquez et al., 2024). La independencia estadística entre la percepción de beneficios y la de riesgos, evidenciada en la baja correlación ($r=.105$) del Capítulo V, es la prueba cuantitativa de este perfil. Para este estudiante, no hay contradicción en afirmar

que ChatGPT es una herramienta excepcional para mejorar la calidad de un ensayo y, al mismo tiempo, desconfiar profundamente de la veracidad de los datos que proporciona (Kurtz et al., 2024).

Los otros dos perfiles identificados por el clustering, el "Escéptico Mínimo" y el "Tecno-Optimista Integrado", actúan como contrapuntos que, por contraste, refuerzan la centralidad del pragmatismo crítico. El "Escéptico" representa a un usuario periférico, cuya falta de experiencia le impide valorar los beneficios, pero tampoco le ha expuesto a los riesgos de manera significativa. El "Tecno-Optimista", por su parte, representa a un subgrupo de entusiastas que, si bien maximizan la percepción de utilidad, tienden a minimizar las preocupaciones éticas y de fiabilidad (Baek et al., 2024). La existencia de estos dos perfiles minoritarios demuestra que, si bien la actitud de la población no es monolítica, la tendencia dominante se aleja de los extremos y se consolida en un espacio intermedio de uso funcional y reflexivo (Kofinas et al., 2025; K. C. Li et al., 2025).

7.3. Diálogo con el marco teórico

Los resultados empíricos de esta investigación dialogan directamente con los marcos teóricos establecidos para comprender la adopción tecnológica y sus implicaciones educativas, validando algunos de sus postulados y, a la vez, exponiendo sus limitaciones frente a una tecnología de esta naturaleza (El-Bayaa et al., 2025; Van Niekerk et al., 2025).

En primer lugar, los hallazgos ofrecen una validación contundente del Modelo de Aceptación Tecnológica (TAM) (K. C. Li et al., 2025). Como postula el TAM, la Utilidad Percibida (constructo de Beneficios) demostró ser un predictor clave de la Intención de Uso (constructo de Visión a Futuro), con una fuerte correlación positiva ($r=.672$). Esto confirma que, en su nivel más básico, la adopción es racional: los estudiantes que perciben beneficios tangibles son los que planean seguir utilizando la tecnología (Lai et al., 2023; Shi et al., 2025).

Sin embargo, este estudio también revela las insuficiencias del TAM para capturar la complejidad de la IA generativa (K. C. Li et al., 2025). Concebido para software determinista y funcional, el modelo no contempla adecuadamente las

dimensiones de riesgo, confianza y ética (Lai et al., 2023). La alta prevalencia de preocupaciones sobre la fiabilidad y su independencia estadística respecto a la utilidad sugieren que el modelo de decisión del estudiante es más sofisticado que un simple cálculo de utilidad y facilidad de uso (Ortiz-Bonnin & Blahopoulou, 2025). La decisión de usar IA generativa implica un cálculo continuo de confianza y una valoración ética contextual que expanden y complejizan la formulación clásica del TAM (Shata & Hartley, 2025).

En segundo lugar, los datos confirman la pertinencia y urgencia del concepto de Alfabetización en IA (AI Literacy) (Al-Abdullatif & Alsubaie, 2024). Los estudiantes de esta muestra demuestran poseer, de manera intuitiva, varios componentes de una alfabetización crítica (Acosta-Enriquez et al., 2024). Su escepticismo ante la exactitud de las respuestas y su preocupación por el impacto en el pensamiento crítico son indicadores de una capacidad para evaluar la información y reflexionar sobre las implicaciones cognitivas de la tecnología (Chan & Hu, 2023).

No obstante, su ambivalencia en torno al plagio ($M=3.11$) revela una laguna significativa en la dimensión ética de esta alfabetización. Esto sugiere que, si bien los estudiantes han desarrollado una comprensión técnica y crítica de la herramienta, carecen de un marco ético claro para navegar su uso en el contexto de la integridad académica, una competencia que evidentemente no están adquiriendo por ósmosis (Smit et al., 2025).

Por último, desde la perspectiva de la psicología educativa, los hallazgos son ambivalentes (Morell-Mengual et al., 2025). La alta valoración de la IA para "entender conceptos complejos" y "completar tareas de forma más eficiente" se alinea con la teoría de la carga cognitiva, donde la herramienta podría estar reduciendo la carga extrínseca (el esfuerzo irrelevante) para liberar recursos mentales para tareas más complejas (Linh, 2025).

Por otro lado, la preocupación explícita por la atrofia del pensamiento crítico refleja una conciencia intuitiva sobre la necesidad del esfuerzo cognitivo para el aprendizaje profundo (Bae et al., 2024; Linh, 2025). Los estudiantes parecen estar en una encrucijada, aprovechando los beneficios de la IA para la eficiencia

sin tener claro cómo hacerlo sin sacrificar los procesos de esfuerzo mental que consolidan el aprendizaje (Acosta-Enriquez et al., 2024).

7.4. Navegando las contradicciones de la era de la IA

Al triangular los hallazgos de esta investigación, emergen con claridad una serie de tensiones fundamentales que caracterizan el estado actual de la IA generativa en la educación superior (Gallent Torres et al., 2023). Estas fricciones no son meros puntos de debate, sino contradicciones estructurales que la comunidad académica en su conjunto está experimentando en tiempo real (Kizilcec et al., 2024).

La primera y más evidente de estas tensiones es la asincronía crítica entre la adopción tecnológica por parte del estudiantado y la capacidad de respuesta, inherentemente más lenta y reflexiva, de la propia universidad (Cambrá-Fierro et al., 2025). Los datos de este estudio son contundentes al mostrar una adopción masiva, regular y eminentemente bottom-up (Smit et al., 2025). Los estudiantes, como nativos digitales, no esperaron un mandato o una guía institucional; de manera orgánica y descentralizada, integraron herramientas como ChatGPT en su flujo de trabajo académico (Morell-Mengual et al., 2025).

Frente a esta realidad fáctica, su percepción es que la institución se encuentra en una posición reactiva, si no ausente (Rudolph et al., 2024). Existe una demanda explícita y mayoritaria de "políticas claras" y de una "integración guiada" por parte de los docentes, lo que contrasta dramáticamente con la percepción generalizada de que "no existen reglas claras" (Barus et al., 2025). Esta brecha temporal y estratégica sitúa a los estudiantes en un estado de considerable incertidumbre normativa, obligándolos a operar en una "zona gris" ética sin el andamiaje institucional que, como demuestran los datos, activamente anhelan (Baek et al., 2024).

La segunda gran tensión se manifiesta en el nivel de la experiencia individual del estudiante, articulándose como un conflicto entre la utilidad pragmática y la incertidumbre ética (Bukar et al., 2024). Los estudiantes han abrazado la IA generativa no por una fascinación abstracta con la tecnología, sino por su

innegable valor instrumental para mejorar la calidad y la eficiencia de su trabajo académico (Fischer et al., 2024).

Sin embargo, esta adopción pragmática coexiste con una profunda ambivalencia sobre su legitimidad (Barus et al., 2025). El hecho de que la consideración de la IA como una forma de plagio se sitúe en el punto medio de la escala es quizás uno de los hallazgos más elocuentes del estudio (Gruenhagen et al., 2024). Este dato revela que no existe un consenso entre el estudiantado sobre dónde trazar la línea divisoria entre la asistencia legítima de una herramienta y el fraude académico que sustituye el esfuerzo intelectual (Smit et al., 2025).

Esta falta de claridad no es trivial; genera una carga cognitiva adicional para el estudiante, quien debe navegar cada tarea académica, desde un simple borrador hasta un proyecto de investigación, con su propio compás ético, sin una guía explícita de lo que es académicamente aceptable (Baek et al., 2024; Smit et al., 2025). Esta tensión es el reflejo de una tecnología que ha desdibujado las fronteras tradicionales de la autoría y la originalidad, dejando al actor más vulnerable del sistema, el estudiante, la responsabilidad de resolver dilemas que la propia academia aún no ha consensuado (Gruenhagen et al., 2024).

La tercera y última tensión es de naturaleza fundamentalmente pedagógica, y se centra en la paradoja entre el empoderamiento cognitivo y el riesgo de dependencia intelectual (Abdaljaleel et al., 2024). Los estudiantes sienten que la IA los empodera, percibiéndola como una herramienta que no solo les permite ser más eficientes, sino también "aprender con mayor profundidad" y "entender conceptos complejos" (Fischer et al., 2024). La ven como un socio que expande sus capacidades cognitivas (Hong et al., 2025).

Al mismo tiempo, y con una intensidad casi idéntica, son elocuentes en su temor a que esa misma herramienta pueda "afectar su capacidad de pensar críticamente" a largo plazo (Smit et al., 2025). Esta es la paradoja central de las "prótesis intelectuales": el riesgo inherente de que la herramienta que aumenta la capacidad en el corto plazo pueda, si se usa de forma acrítica, erosionar la habilidad subyacente que pretende apoyar (Bukar et al., 2024; Kim et al., 2025).

Los estudiantes están viviendo esta tensión en tiempo real, experimentando con una tecnología que puede actuar tanto como andamio para el pensamiento como

sustituto del mismo (Hong et al., 2025). La ausencia de estrategias pedagógicas claras por parte de la institución los deja solos en este delicado equilibrio, sin una guía explícita sobre cómo utilizar la IA para potenciar su aprendizaje sin externalizar el esfuerzo mental que es, en sí mismo, el motor del desarrollo intelectual (Gasaymeh et al., 2024; Smit et al., 2025).

7.5. Implicaciones para la política y la práctica educativa

Los hallazgos de esta investigación no son meramente descriptivos; constituyen una hoja de ruta detallada para la acción institucional, con implicaciones directas y urgentes para la comunidad de educación superior (Barus et al., 2025). La principal conclusión para los gestores y administradores universitarios es la necesidad imperiosa de transitar desde una postura reactiva, a menudo caracterizada por la incertidumbre o la prohibición implícita, hacia una estrategia proactiva de integración y gobernanza de la IA (Cacho, 2024; Rudolph et al., 2024). El "llamado a la institucionalización" expresado por los estudiantes es inequívoco y debe ser atendido (Barus et al., 2025).

Esto implica, en primer lugar, el desarrollo de políticas de integridad académica que sean claras, matizadas y, sobre todo, educativas en lugar de meramente punitivas (Barus et al., 2025; Moore & Lookadoo, 2024). Estas políticas no pueden reducirse a un simple "prohibido usar IA", sino que deben reconocer el espectro de usos posibles, ofreciendo ejemplos concretos que diferencien entre la asistencia legítima para la ideación o mejora estilística y el fraude académico que implica la sustitución del esfuerzo intelectual (Moore & Lookadoo, 2024).


Además, el descubrimiento de tres perfiles de usuario distintos mediante machine learning tiene una implicación estratégica directa: la formación en IA no puede ser genérica (Chiu, 2024). Las universidades deben diseñar intervenciones pedagógicas y programas de alfabetización digital que sean segmentados y personalizados (Kurtz et al., 2024). Para los "Tecno-Optimistas", el foco formativo no debería centrarse en fomentar una adopción que ya es completa, sino en cultivar un escepticismo saludable y una reflexión ética profunda (Oliveira et al., 2025).

Para el perfil mayoritario de los "Pragmáticos Críticos", las intervenciones deberían validar sus preocupaciones y ofrecerles herramientas avanzadas para la gestión de riesgos, como técnicas de verificación de información y estrategias de prompt engineering para mitigar sesgos (Van Niekerk et al., 2025). Finalmente, para los "Escépticos Mínimos", la estrategia debe ser de sensibilización y demostración, mostrando el valor instrumental tangible de estas herramientas en sus disciplinas específicas (Gruenhagen et al., 2024).

Para los docentes y el personal académico, la ubicuidad de la IA generativa obliga a una profunda reflexión sobre su rol y sobre el diseño de la experiencia de aprendizaje (Fischer et al., 2024). Las implicaciones prácticas son profundas, comenzando por un rediseño de las estrategias de evaluación (Kizilcec et al., 2024). Las evaluaciones tradicionales basadas en productos finales escritos fuera del aula se han vuelto inherentemente vulnerables (Kolade et al., 2024).

Es imperativo transitar hacia métodos que enfaticen el proceso, no solo el producto: presentaciones orales, debates en clase, análisis de casos en tiempo real, portafolios reflexivos y, crucialmente, evaluaciones basadas en la capacidad de criticar, verificar y mejorar los resultados generados por una IA (Almpanis et al., 2025; Kizilcec et al., 2024). En lugar de ignorar o prohibir estas herramientas, los docentes deben integrarlas explícitamente en el currículo, enseñando su uso ético y eficaz como una nueva competencia fundamental (Gruenhagen et al., 2024).

Este cambio de enfoque conlleva una evolución del rol docente, desde un "proveedor de contenido" hacia un "curador y guía cognitivo" (Kurtz et al., 2024). En un mundo donde la información es generada de forma abundante por la IA, el valor diferencial del educador humano se desplaza hacia el desarrollo de competencias de orden superior que las máquinas no pueden replicar: el pensamiento crítico, la síntesis interdisciplinaria y, sobre todo, el juicio ético (Fischer et al., 2024; Nikolic, Wentworth, et al., 2024).



CAPITULO 08

CONCLUSIONES Y FUTURAS LÍNEAS DE INVESTIGACIÓN

Conclusiones y futuras líneas de investigación

8.1. Síntesis de los Principales Hallazgos

Esta investigación se propuso analizar de manera sistemática la interacción del estudiantado universitario con las herramientas de IA generativa. A través de un enfoque cuantitativo complementado con técnicas de machine learning, se ha construido una radiografía detallada de este fenómeno.

El perfil del usuario que ha adoptado la IA es transversal y nativo digital. Se trata de un estudiante joven, cuyo uso de estas tecnologías se extiende a todas las áreas del conocimiento y niveles académicos, con ChatGPT como la herramienta hegemónica.

La percepción dominante que define a esta población es la del "pragmatismo crítico". Esta actitud se caracteriza por una dualidad en la que coexisten una alta valoración de los beneficios de la IA en términos de eficiencia y aprendizaje, junto a una profunda y extendida conciencia de sus riesgos, especialmente en lo que respecta a la fiabilidad de la información.

La experiencia con la IA, además, parece ser homogénea. Los análisis no encontraron diferencias significativas en las percepciones en función del género o del año de estudio. Esta uniformidad actitudinal se acompaña de una demanda unívoca y transversal hacia la institución: los estudiantes desean políticas claras y una integración pedagógica guiada.

Bajo esta tendencia general, el análisis de clustering reveló la coexistencia de tres arquetipos de usuario bien diferenciados: el "Escéptico Mínimo", un usuario indiferente; el "Pragmático Crítico", el grupo mayoritario que equilibra el uso intensivo con la conciencia de los riesgos; y el "Tecno-Optimista Integrado", un entusiasta que maximiza los beneficios y minimiza las preocupaciones.

Finalmente, se demostró que la adopción de la IA a largo plazo es un comportamiento predecible. Los modelos de machine learning lograron anticipar con una alta exactitud (88.1%) la intención de un estudiante de continuar

utilizando estas herramientas, confirmando que la adopción responde a patrones consistentes y no a un comportamiento aleatorio.

8.2. Contribuciones de la investigación

Este estudio aporta valor en tres dimensiones interconectadas. Su principal contribución científica es la evidencia empírica a gran escala del perfil "crítico-pragmático", superando la dicotomía simplista de oportunidades vs. riesgos. La identificación de tres arquetipos de usuario ofrece, además, una taxonomía novedosa y más granular para comprender a la comunidad estudiantil.

Metodológicamente, el libro demuestra el potencial de combinar la estadística tradicional con técnicas de machine learning para la investigación educativa. Este trabajo sirve como un caso de estudio sobre cómo la ciencia de datos puede transformar datos de encuestas en inteligencia estratégica, ofreciendo un modelo replicable.

Para las instituciones, esta investigación proporciona un diagnóstico empírico y una base de evidencia para la toma de decisiones. En lugar de operar sobre anécdotas, los gestores pueden utilizar estos hallazgos para diseñar políticas informadas y programas de formación segmentados.

8.3. Recomendaciones estratégicas

A partir de los hallazgos, se derivan una serie de recomendaciones concretas para los actores clave del ecosistema de educación superior. Para las universidades, es fundamental superar la prohibición y abrazar una gobernanza activa, desarrollando políticas de integridad académica que sean claras y educativas. Es igualmente crucial implementar programas de formación en IA que sean segmentados, utilizando la taxonomía de perfiles (Escéptico, Pragmático Crítico, Tecno-Optimista) para diseñar intervenciones que respondan a las necesidades específicas de cada grupo. Asimismo, se debe invertir en el desarrollo de competencias pedagógicas en el profesorado.

Para los docentes, la recomendación principal es reimaginar la evaluación. Es necesario transitar hacia métodos que midan el proceso y el pensamiento crítico, en lugar de productos finales fácilmente automatizables. Se debe, además, integrar la IA como objeto de estudio dentro de las asignaturas, enseñando activamente a los estudiantes a interactuar con ella de manera eficaz y ética. Finalmente, el rol docente debe evolucionar hacia el de un guía cognitivo, centrado en el desarrollo de las habilidades de orden superior que marcan la diferencia fundamental entre la cognición humana y la artificial.

8.4. Limitaciones y futuras líneas de investigación

Toda investigación tiene sus límites. Este estudio presenta tres principales: su naturaleza transversal, que ofrece una fotografía de un momento específico; su enfoque en una única institución, lo que requiere cautela al generalizar los hallazgos; y su dependencia de datos de autoinforme.

A partir de estas limitaciones, se proponen varias líneas de investigación futuras. Es fundamental realizar estudios longitudinales que rastreen la evolución de los perfiles y percepciones a lo largo del tiempo. También son necesarias las investigaciones comparativas en diversas instituciones para identificar factores contextuales. Los estudios cualitativos, como entrevistas en profundidad con estudiantes de cada uno de los tres perfiles, permitirían explorar las motivaciones subyacentes que explican sus actitudes. Finalmente, se abren nuevas vías para la investigación experimental, que mida el impacto real de la IA en los resultados de aprendizaje, y para el análisis de las percepciones y necesidades del propio profesorado.

8.5. La IA como fenómeno cultural y educativo


La irrupción de la IA generativa en la universidad trasciende la mera introducción de una nueva herramienta. Lo que esta investigación ha revelado es la consolidación de un nuevo socio cognitivo, un exo-córtex digital con el que una generación de nativos digitales ya dialoga de forma natural. La IA no es un añadido externo; se está convirtiendo en una capa fundamental de la

infraestructura a través de la cual los estudiantes acceden, procesan y producen conocimiento.

Este fenómeno obliga a la universidad a confrontar preguntas que tocan el núcleo de su misión. ¿Qué significa pensar críticamente en una era de cognición aumentada? ¿Cómo se cultiva una voz autoral auténtica cuando la generación de texto es instantánea? ¿Cuál es el valor del esfuerzo intelectual cuando las respuestas parecen estar a un clic de distancia?

La respuesta no reside en la prohibición ni en la adopción acrítica, sino en la sabiduría pedagógica. El perfil del "pragmático crítico", emergente como dominante en este estudio, es una fuente de optimismo. Muestra a una comunidad estudiantil que no está dispuesta a delegar su juicio, que valora la eficiencia, pero anhela la guía.

El reto para la educación superior del siglo XXI será estar a la altura de la madurez de sus estudiantes. La tarea no es protegerlos de la IA, sino educarlos para que puedan colaborar con ella de manera sabia, ética y profundamente humana. Si la universidad logra esto, la IA generativa no será la tecnología que atrofió el pensamiento, sino la que lo catalizó hacia nuevas fronteras. El futuro no pertenece a la IA, sino a la inteligencia humana que aprenda a potenciarla con propósito y conciencia.



Referencias Bibliográficas

Referencias Bibliográficas

- Abdaljaleel, M., Barakat, M., Alsanafi, M., Salim, N. A., Abazid, H., Malaeb, D., Mohammed, A. H., Hassan, B. A. R., Wayyes, A. M., Farhan, S. S., Khatib, S. E., Rahal, M., Sahban, A., Abdelaziz, D. H., Mansour, N. O., AlZayer, R., Khalil, R., Fekih-Romdhane, F., Hallit, R., ... Sallam, M. (2024). A multinational study on the factors influencing university students' attitudes and usage of ChatGPT. *Scientific Reports*, 14(1), 1983. <https://doi.org/10.1038/s41598-024-52549-8>
- Abdi, A.-N. M., Omar, A. M., Ahmed, M. H., & Ahmed, A. A. (2025). The predictors of behavioral intention to use ChatGPT for academic purposes: Evidence from higher education in Somalia. *Cogent Education*, 12(1), 2460250. <https://doi.org/10.1080/2331186X.2025.2460250>
- Acosta-Enriquez, B. G., Arbulú Pérez Vargas, C. G., Huamaní Jordan, O., Arbulú Ballesteros, M. A., & Paredes Morales, A. E. (2024). Exploring attitudes toward ChatGPT among college students: An empirical analysis of cognitive, affective, and behavioral components using path analysis. *Computers and Education: Artificial Intelligence*, 7, 100320. <https://doi.org/10.1016/j.caeai.2024.100320>
- Aguilos, V., & Fuchs, K. (2024). Using an extended Technology Acceptance Model (eTAM) to determine university students' behavioral intentions of ChatGPT: An empirical study from Thailand. *Qwerty. Open and Interdisciplinary Journal of Technology, Culture and Education*, 19(2). <https://doi.org/10.30557/QW000088>
- Al-Abdullatif, A. M., & Alsubaie, M. A. (2024). ChatGPT in Learning: Assessing Students' Use Intentions through the Lens of Perceived Value and the Influence of AI Literacy. *Behavioral Sciences*, 14(9), 845. <https://doi.org/10.3390/bs14090845>
- Almassaad, A., Alajlan, H., & Alebaikan, R. (2024). Student Perceptions of Generative Artificial Intelligence: Investigating Utilization, Benefits, and Challenges in Higher Education. *Systems*, 12(10), 385. <https://doi.org/10.3390/systems12100385>
- Almpanis, T., Conroy, D., & Joseph-Richard, P. (2025). Practical Implications of Generative AI on Assessment: Snapshot of Early Reactions to Assessment Redesign in an HRM and a Psychology Course. *Electronic Journal of E-Learning*, 23(3), 19-29. <https://doi.org/10.34190/ejel.23.3.3971>
- An, Y., Yu, J. H., & James, S. (2025). Investigating the higher education institutions' guidelines and policies regarding the use of generative AI in teaching, learning, research, and administration. *International Journal of Educational Technology in Higher Education*, 22(1), 10. <https://doi.org/10.1186/s41239-025-00507-3>

- Bae, H., Hur, J., Park, J., Choi, G. W., & Moon, J. (2024). Pre-service Teachers' Dual Perspectives on Generative AI: Benefits, Challenges, and Integrating into Teaching and Learning. *Online Learning*, 28(3). <https://doi.org/10.24059/olj.v28i3.4543>
- Baek, C., Tate, T., & Warschauer, M. (2024). "ChatGPT seems too good to be true": College students' use and perceptions of generative AI. *Computers and Education: Artificial Intelligence*, 7, 100294. <https://doi.org/10.1016/j.caeai.2024.100294>
- Balaskas, S., Tsiantos, V., Chatzifotiou, S., & Rigou, M. (2025). Determinants of ChatGPT Adoption Intention in Higher Education: Expanding on TAM with the Mediating Roles of Trust and Risk. *Information*, 16(2), 82. <https://doi.org/10.3390/info16020082>
- Barakat, M. (2025). University Educators Perspectives on ChatGPT: A Technology Acceptance Model-Based Study. *Open Praxis*. <https://doi.org/10.55982/openpraxis.17.1.718>
- Barus, O. P., Hidayanto, A. N., Handri, E. Y., Sensuse, D. I., & Yaiprasert, C. (2025). Shaping generative AI governance in higher education: Insights from student perception. *International Journal of Educational Research Open*, 8, 100452. <https://doi.org/10.1016/j.ijedro.2025.100452>
- Bhullar, P. S., Joshi, M., & Chugh, R. (2024). ChatGPT in higher education—A synthesis of the literature and a future research agenda. *Education and Information Technologies*, 29(16), 21501-21522. <https://doi.org/10.1007/s10639-024-12723-x>
- Borges, B., Foroutan, N., Bayazit, D., Sotnikova, A., Montariol, S., Nazaretsky, T., Banaei, M., Sakhaeirad, A., Servant, P., Neshaei, S. P., Frej, J., Romanou, A., Weiss, G., Mamooler, S., Chen, Z., Fan, S., Gao, S., Ismayilzada, M., Paul, D., ... EPFL Data Consortium. (2024). Could ChatGPT get an engineering degree? Evaluating higher education vulnerability to AI assistants. *Proceedings of the National Academy of Sciences*, 121(49), e2414955121. <https://doi.org/10.1073/pnas.2414955121>
- Bukar, U. A., Sayeed, M. S., Abdul Razak, S. F., Yogarayan, S., & Ahmed Amodu, O. (2024). An integrative decision-making framework to guide policies on regulating ChatGPT usage. *PeerJ Computer Science*, 10, e1845. <https://doi.org/10.7717/peerj-cs.1845>
- Cabero-Almenara, J., Palacios-Rodríguez, A., Rojas Guzmán, H. D. L. Á., & Fernández-Scagliusi, V. (2025). Prediction of the Use of Generative Artificial Intelligence Through ChatGPT Among Costa Rican University Students: A PLS Model Based on UTAUT2. *Applied Sciences*, 15(6), 3363. <https://doi.org/10.3390/app15063363>
- Cacho, R. (2024). Integrating Generative AI in University Teaching and Learning: A Model for Balanced Guidelines. *Online Learning*, 28(3). <https://doi.org/10.24059/olj.v28i3.4508>

Referencias:

- Cambra-Fierro, J. J., Blasco, M. F., López-Pérez, M.-E. E., & Trifu, A. (2025). ChatGPT adoption and its influence on faculty well-being: An empirical research in higher education. *Education and Information Technologies*, 30(2), 1517-1538. <https://doi.org/10.1007/s10639-024-12871-0>
- Cardona, M. A., Rodríguez, R. J., & Ishmael, K. (2023). *Artificial Intelligence and the Future of Teaching and Learning*.
- 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(1), 43. <https://doi.org/10.1186/s41239-023-00411-8>
- Chen, Y., Wang, Y., Wüstenberg, T., Kizilcec, R., Fan, Y., Li, Y., Lu, B., Yuan, M., Zhang, J., Zhang, Z., Geldsetzer, P., Chen, S., & Bärnighausen, T. (2025). *Effects of generative artificial intelligence on cognitive effort and task performance: Study protocol for a randomized controlled experiment among college students*. In Review. <https://doi.org/10.21203/rs.3.rs-5557709/v1>
- Chiu, T. K. F. (2024). Future research recommendations for transforming higher education with generative AI. *Computers and Education: Artificial Intelligence*, 6, 100197. <https://doi.org/10.1016/j.caeai.2023.100197>
- Dabis, A., & Csáki, C. (2024). AI and ethics: Investigating the first policy responses of higher education institutions to the challenge of generative AI. *Humanities and Social Sciences Communications*, 11(1), 1006. <https://doi.org/10.1057/s41599-024-03526-z>
- Đerić, E., Frank, D., & Milković, M. (2025). Trust in Generative AI Tools: A Comparative Study of Higher Education Students, Teachers, and Researchers. *Information*, 16(7), 622. <https://doi.org/10.3390/info16070622>
- Driessens, O., & Pischetola, M. (2024). Danish university policies on generative AI: Problems, assumptions and sustainability blind spots. *MedieKultur: Journal of Media and Communication Research*, 40(76), 31-52. <https://doi.org/10.7146/mk.v40i76.143595>
- El-Bayaa, N., Alzoubi, Y. I., & Mishra, A. (2025). Adoption ChatGPT in higher education settings: Potentials, challenges, and paving the way for future advancements. *Edelweiss Applied Science and Technology*, 9(5), 2940-2964. <https://doi.org/10.55214/25768484.v9i5.7618>
- Fischer, I., Sweeney, S., Lucas, M., & Gupta, N. (2024). Making sense of generative AI for assessments: Contrasting student claims and assessor evaluations. *The International Journal of Management Education*, 22(3), 101081. <https://doi.org/10.1016/j.ijme.2024.101081>
- Gallent Torres, C., Zapata González, A., & Ortego Hernando, J. L. (2023). El impacto de la inteligencia artificial generativa en educación superior: Una mirada desde la ética y la integridad académica. *RELIEVE - Revista Electrónica de Investigación y Evaluación Educativa*, 29(2). <https://doi.org/10.30827/relieve.v29i2.29134>

Referencias:

- Gasaymeh, A.-M. M., Beirat, M. A., & Abu Qbeita, A. A. (2024). University Students' Insights of Generative Artificial Intelligence (AI) Writing Tools. *Education Sciences*, 14(10), 1062. <https://doi.org/10.3390/educsci14101062>
- Greiner, C., Peisl, T. C., Höpfl, F., & Beese, O. (2023). Acceptance of AI in Semi-Structured Decision-Making Situations Applying the Four-Sides Model of Communication—An Empirical Analysis Focused on Higher Education. *Education Sciences*, 13(9), 865. <https://doi.org/10.3390/educsci13090865>
- Gruenhagen, J. H., Sinclair, P. M., Carroll, J.-A., Baker, P. R. A., Wilson, A., & Demant, D. (2024). The rapid rise of generative AI and its implications for academic integrity: Students' perceptions and use of chatbots for assistance with assessments. *Computers and Education: Artificial Intelligence*, 7, 100273. <https://doi.org/10.1016/j.caeai.2024.100273>
- Haroud, S., & Saqri, N. (2025). Generative AI in Higher Education: Teachers' and Students' Perspectives on Support, Replacement, and Digital Literacy. *Education Sciences*, 15(4), 396. <https://doi.org/10.3390/educsci15040396>
- Hong, H., Vate-U-Lan, P., & Viriyavejakul, C. (2025). Cognitive Offload Instruction with Generative AI: A Quasi-Experimental Study on Critical Thinking Gains in English Writing. *Forum for Linguistic Studies*, 7(7). <https://doi.org/10.30564/fls.v7i7.10072>
- Huang, J., & Mizumoto, A. (2024). Examining the relationship between the L2 motivational self system and technology acceptance model post ChatGPT introduction and utilization. *Computers and Education: Artificial Intelligence*, 7, 100302. <https://doi.org/10.1016/j.caeai.2024.100302>
- Iulian, Î., Roxana, V. D., Codrin Florentin, N., & Cătălin, P. (2024). Generative Artificial Intelligence and the Academic Integrity of Graduation Works in Economics – Exploring Perceptions of Romanian Academia. *ECONOMIC COMPUTATION AND ECONOMIC CYBERNETICS STUDIES AND RESEARCH*, 58(2/2024), 132-147. <https://doi.org/10.24818/18423264/58.2.24.08>
- Jensen, L. X., Buhl, A., Sharma, A., & Bearman, M. (2025). Generative AI and higher education: A review of claims from the first months of ChatGPT. *Higher Education*, 89(4), 1145-1161. <https://doi.org/10.1007/s10734-024-01265-3>
- Jiang, Y., Xie, L., & Cao, X. (2025). Exploring the Effectiveness of Institutional Policies and Regulations for Generative AI Usage in Higher Education. *Higher Education Quarterly*, 79(4), e70054. <https://doi.org/10.1111/hequ.70054>
- Jin, Y., Yan, L., Echeverria, V., Gašević, D., & Martinez-Maldonado, R. (2025). Generative AI in higher education: A global perspective of institutional adoption policies and guidelines. *Computers and Education: Artificial Intelligence*, 8, 100348. <https://doi.org/10.1016/j.caeai.2024.100348>
- Kanont, K., Pingmuang, P., Simasathien, T., Wisnuwong, S., Wiwatsiripong, B., Poonpirome, K., Songkram, N., & Khlaisang, J. (2024). Generative-AI, a

- Learning Assistant? Factors Influencing Higher-Ed Students' Technology Acceptance. *Electronic Journal of E-Learning*, 22(6), 18-33. <https://doi.org/10.34190/ejel.22.6.3196>
- Khan, R., Qamar, Md. T., Ansari, M. S., & Yasmeen, J. (2025). Enhancing or impairing? Exploring Indian EFL learners' academic writing narratives with ChatGPT. *Cogent Education*, 12(1), 2514329. <https://doi.org/10.1080/2331186X.2025.2514329>
- Kim, J., Klopfer, M., Grohs, J. R., Eldardiry, H., Weichert, J., Cox, L. A., & Pike, D. (2025). Examining Faculty and Student Perceptions of Generative AI in University Courses. *Innovative Higher Education*, 50(4), 1281-1313. <https://doi.org/10.1007/s10755-024-09774-w>
- Kizilcec, R. F., Huber, E., Papanastasiou, E. C., Cram, A., Makridis, C. A., Smolansky, A., Zeivots, S., & Radulescu, C. (2024). Perceived impact of generative AI on assessments: Comparing educator and student perspectives in Australia, Cyprus, and the United States. *Computers and Education: Artificial Intelligence*, 7, 100269. <https://doi.org/10.1016/j.caeai.2024.100269>
- Kofinas, A. K., Tsay, C. H., & Pike, D. (2025). The impact of generative AI on academic integrity of authentic assessments within a higher education context. *British Journal of Educational Technology*, bjet.13585. <https://doi.org/10.1111/bjet.13585>
- Kolade, O., Owoseni, A., & Egbetokun, A. (2024). Is AI changing learning and assessment as we know it? Evidence from a ChatGPT experiment and a conceptual framework. *Heliyon*, 10(4), e25953. <https://doi.org/10.1016/j.heliyon.2024.e25953>
- Krzysztof, W., & Wojciech, C. (2023). Challenges for higher education in the era of widespread access to Generative AI. *Economics and Business Review*, 9(2). <https://doi.org/10.18559/ebr.2023.2.743>
- Kurtz, G., Amzalag, M., Shaked, N., Zaguri, Y., Kohen-Vacs, D., Gal, E., Zailer, G., & Barak-Medina, E. (2024). Strategies for Integrating Generative AI into Higher Education: Navigating Challenges and Leveraging Opportunities. *Education Sciences*, 14(5), 503. <https://doi.org/10.3390/educsci14050503>
- L. Cutillas, A. (2025). Generative AI as a catalyst for instruction in higher education: A study on relevance and effectiveness. *Environment and Social Psychology*, 10(4). <https://doi.org/10.59429/esp.v10i4.3185>
- Lai, C. Y., Cheung, K. Y., & Chan, C. S. (2023). Exploring the role of intrinsic motivation in ChatGPT adoption to support active learning: An extension of the technology acceptance model. *Computers and Education: Artificial Intelligence*, 5, 100178. <https://doi.org/10.1016/j.caeai.2023.100178>
- Li, J., Jangamreddy, N. K., Hisamoto, R., Bhansali, R., Dyda, A., Zaphir, L., & Glencross, M. (2024). AI-assisted marking: Functionality and limitations of

- ChatGPT in written assessment evaluation. *Australasian Journal of Educational Technology*. <https://doi.org/10.14742/ajet.9463>
- Li, K. C., Chong, G. H. L., Wong, B. T. M., & Wu, M. M. F. (2025). A TAM-Based Analysis of Hong Kong Undergraduate Students' Attitudes Toward Generative AI in Higher Education and Employment. *Education Sciences*, 15(7), 798. <https://doi.org/10.3390/educsci15070798>
- Linh, T. T. (2025). Factors influencing the use of ChatGPT in student learning in Vietnam. *International Journal of ADVANCED AND APPLIED SCIENCES*, 12(7), 76-86. <https://doi.org/10.21833/ijaas.2025.07.007>
- Marengo, A., Karaoglan-Yilmaz, F. G., Yilmaz, R., & Ceylan, M. (2025). Development and validation of generative artificial intelligence attitude scale for students. *Frontiers in Computer Science*, 7, 1528455. <https://doi.org/10.3389/fcomp.2025.1528455>
- Michel-Villarreal, R., Vilalta-Perdomo, E., Salinas-Navarro, D. E., Thierry-Aguilera, R., & Gerardou, F. S. (2023). Challenges and Opportunities of Generative AI for Higher Education as Explained by ChatGPT. *Education Sciences*, 13(9), 856. <https://doi.org/10.3390/educsci13090856>
- Moore, S., & Lookadoo, K. (2024). Communicating Clear Guidance: Advice for Generative AI Policy Development in Higher Education. *Business and Professional Communication Quarterly*, 87(4), 610-629. <https://doi.org/10.1177/23294906241254786>
- Morell-Mengual, V., Fernández-García, O., Berenguer, C., Ortega-Barón, J., Gil-Llario, M. D., & Estruch-García, V. (2025). Characteristics, motivations and attitudes of students using ChatGPT and other language model-based chatbots in higher education. *Education and Information Technologies*. <https://doi.org/10.1007/s10639-025-13650-1>
- Mourtajji, L., & Arts-Chiss, N. (2024). Unleashing ChatGPT: Redefining Technology Acceptance and Digital Transformation in Higher Education. *Administrative Sciences*, 14(12), 325. <https://doi.org/10.3390/admsci14120325>
- Namatovu, A., & Kyambade, M. (2025). Leveraging AI in academia: University students' adoption of ChatGPT for writing coursework (take home) assignments through the lens of UTAUT2. *Cogent Education*, 12(1), 2485522. <https://doi.org/10.1080/2331186X.2025.2485522>
- Nartey, E. K. (2024). Guiding principles of generative AI for employability and learning in UK universities. *Cogent Education*, 11(1), 2357898. <https://doi.org/10.1080/2331186X.2024.2357898>
- Nikolic, S., Sandison, C., Haque, R., Daniel, S., Grundy, S., Belkina, M., Lyden, S., Hassan, G. M., & Neal, P. (2024). ChatGPT, Copilot, Gemini, SciSpace and Wolfram versus higher education assessments: An updated multi-institutional study of the academic integrity impacts of Generative Artificial Intelligence (GenAI) on assessment, teaching and learning in engineering. *Australasian Journal of Engineering Education*, 29(2), 126-153. <https://doi.org/10.1080/22054952.2024.2372154>

- Nikolic, S., Wentworth, I., Sheridan, L., Moss, S., Duursma, E., Jones, R. A., Ros, M., & Middleton, R. (2024). A systematic literature review of attitudes, intentions and behaviours of teaching academics pertaining to AI and generative AI (GenAI) in higher education: An analysis of GenAI adoption using the UTAUT framework. *Australasian Journal of Educational Technology*. <https://doi.org/10.14742/ajet.9643>
- Oc, Y., Gonsalves, C., & Quamina, L. T. (2025). Generative AI in Higher Education Assessments: Examining Risk and Tech-Savviness on Student's Adoption. *Journal of Marketing Education*, 47(2), 138-155. <https://doi.org/10.1177/02734753241302459>
- Oliveira, L., Tavares, C., Strzelecki, A., & Silva, M. (2025). Prompting Minds: Evaluating how Students Perceive Generative AI's Critical Thinking Dispositions. *Electronic Journal of E-Learning*, 23(2), 1-18. <https://doi.org/10.34190/ejel.23.2.3986>
- Ortiz-Bonnin, S., & Blahopoulou, J. (2025). Chat or cheat? Academic dishonesty, risk perceptions, and ChatGPT usage in higher education students. *Social Psychology of Education*, 28(1), 113. <https://doi.org/10.1007/s11218-025-10080-2>
- Pavlenko, O., & Syzenko, A. (2024). Using ChatGPT as a Learning Tool: A Study of Ukrainian Students' Perceptions. *Arab World English Journal*, 1(1), 252-264. <https://doi.org/10.24093/awej/ChatGPT.17>
- Qian, Y. (2025). Pedagogical Applications of Generative AI in Higher Education: A Systematic Review of the Field. *TechTrends*. <https://doi.org/10.1007/s11528-025-01100-1>
- Rudolph, J., Mohamed Ismail, F. M., & Popenici, S. (2024). Higher Education's Generative Artificial Intelligence Paradox: The Meaning of Chatbot Mania. *Journal of University Teaching and Learning Practice*, 21(06). <https://doi.org/10.53761/54fs5e77>
- Ruiz-Rojas, L. I., Salvador-Ullauri, L., & Acosta-Vargas, P. (2024). Collaborative Working and Critical Thinking: Adoption of Generative Artificial Intelligence Tools in Higher Education. *Sustainability*, 16(13), 5367. <https://doi.org/10.3390/su16135367>
- Sallam, M., Elsayed, W., Al-Shorbagy, M., Barakat, M., El Khatib, S., Ghach, W., Alwan, N., Hallit, S., & Malaeb, D. (2024). ChatGPT usage and attitudes are driven by perceptions of usefulness, ease of use, risks, and psycho-social impact: A study among university students in the UAE. *Frontiers in Education*, 9, 1414758. <https://doi.org/10.3389/feduc.2024.1414758>
- Sergeeva, O. V., Masalimova, A. R., Zheltukhina, M. R., Chikileva, L. S., Lutskovskai, L. Yu., & Luzin, A. (2025). Impact of digital media literacy on attitude toward generative AI acceptance in higher education. *Frontiers in Education*, 10, 1563148. <https://doi.org/10.3389/feduc.2025.1563148>
- Shahzad, M. F., Xu, S., & Javed, I. (2024). ChatGPT awareness, acceptance, and adoption in higher education: The role of trust as a cornerstone.

- International Journal of Educational Technology in Higher Education*, 21(1), 46. <https://doi.org/10.1186/s41239-024-00478-x>
- Shanto, S. S., Ahmed, Z., & Jony, A. I. (2023). PAIGE: A generative AI-based framework for promoting assignment integrity in higher education. *STEM Education*, 3(4), 288-305. <https://doi.org/10.3934/steme.2023018>
- Shata, A., & Hartley, K. (2025). Artificial intelligence and communication technologies in academia: Faculty perceptions and the adoption of generative AI. *International Journal of Educational Technology in Higher Education*, 22(1), 14. <https://doi.org/10.1186/s41239-025-00511-7>
- Shi, J., Liu, W., & Hu, K. (2025). Exploring How AI Literacy and Self-Regulated Learning Relate to Student Writing Performance and Well-Being in Generative AI-Supported Higher Education. *Behavioral Sciences*, 15(5), 705. <https://doi.org/10.3390/bs15050705>
- Singh, R. G., & Ngai, C. S. B. (2024). Top-ranked U.S. and U.K.'s universities' first responses to GenAI: Key themes, emotions, and pedagogical implications for teaching and learning. *Discover Education*, 3(1), 115. <https://doi.org/10.1007/s44217-024-00211-w>
- Smit, M., Wagner, R. F., & Bond-Barnard, T. J. (2025). Ambiguous regulations for dealing with AI in higher education can lead to moral hazards among students. *Project Leadership and Society*, 6, 100187. <https://doi.org/10.1016/j.plas.2025.100187>
- Sousa, A. E., & Cardoso, P. (2025). Use of Generative AI by Higher Education Students. *Electronics*, 14(7), 1258. <https://doi.org/10.3390/electronics14071258>
- Szűts, Z., Lengyelne Molnár, T., Racskó, R., Vaughan, G., Ceglédi, S., & Dominek, D. (2025). Examining the Flow Dynamics of Artificial Intelligence in Real-Time Classroom Applications. *Computers*, 14(7), 275. <https://doi.org/10.3390/computers14070275>
- Tala, M. L., Muller, C. N., Nastase, I. A., State, O., & Gheorghe, G. (2024). Exploring University Students Perceptions of Generative Artificial Intelligence in Education. *Amfiteatru Economic*, 26(65), 71. <https://doi.org/10.24818/EA/2024/65/71>
- Ursavaş, Ö. F., Yalçın, Y., İslamoğlu, H., Bakır-Yalçın, E., & Cukurova, M. (2025). Rethinking the importance of social norms in generative AI adoption: Investigating the acceptance and use of generative AI among higher education students. *International Journal of Educational Technology in Higher Education*, 22(1), 38. <https://doi.org/10.1186/s41239-025-00535-z>
- Van Den Berg, G., & Du Plessis, E. (2023). ChatGPT and Generative AI: Possibilities for Its Contribution to Lesson Planning, Critical Thinking and Openness in Teacher Education. *Education Sciences*, 13(10), 998. <https://doi.org/10.3390/educsci13100998>
- Van Niekerk, J., Delport, P. M. J., & Sutherland, I. (2025). Addressing the use of generative AI in academic writing. *Computers and Education: Artificial Intelligence*, 8, 100342. <https://doi.org/10.1016/j.caeai.2024.100342>

Referencias:

- Wang, H., Dang, A., Wu, Z., & Mac, S. (2024). Generative AI in higher education: Seeing ChatGPT through universities' policies, resources, and guidelines. *Computers and Education: Artificial Intelligence*, 7, 100326. <https://doi.org/10.1016/j.caeai.2024.100326>
- Wang, L., & Ren, B. (2024). Enhancing Academic Writing in a Linguistics Course with Generative AI: An Empirical Study in a Higher Education Institution in Hong Kong. *Education Sciences*, 14(12), 1329. <https://doi.org/10.3390/educsci14121329>
- Wu, C., Zhang, H., & Carroll, J. M. (2024). AI Governance in Higher Education: Case Studies of Guidance at Big Ten Universities. *Future Internet*, 16(10), 354. <https://doi.org/10.3390/fi16100354>
- Wu, Q., Tian, J., & Liu, Z. (2025). Exploring the usage behavior of generative artificial intelligence: A case study of ChatGPT with insights into the moderating effects of habit and personal innovativeness. *Current Psychology*, 44(9), 8190-8203. <https://doi.org/10.1007/s12144-024-07193-w>
- Zaim, M., Arsyad, S., Waluyo, B., Ardi, H., Al Hafizh, Muhd., Zakiyah, M., Syafitri, W., Nusi, A., & Hardiah, M. (2024). AI-powered EFL pedagogy: Integrating generative AI into university teaching preparation through UTAUT and activity theory. *Computers and Education: Artificial Intelligence*, 7, 100335. <https://doi.org/10.1016/j.caeai.2024.100335>
- Zhao, X., Cox, A., & Cai, L. (2024). ChatGPT and the digitisation of writing. *Humanities and Social Sciences Communications*, 11(1), 482. <https://doi.org/10.1057/s41599-024-02904-x>

RESUMEN

Este estudio aborda la brecha crítica entre la rápida y masiva adopción de la inteligencia artificial generativa por parte de los estudiantes y la lenta capacidad de respuesta de las instituciones de educación superior. Para informar el desarrollo de políticas y estrategias pedagógicas efectivas, se realizó una investigación cuantitativa mediante una encuesta validada, aplicada a una muestra de 474 estudiantes universitarios en Ecuador. El análisis de datos combinó estadísticas descriptivas e inferenciales con técnicas de machine learning en Python, incluyendo el algoritmo de agrupamiento K-Means para la segmentación de perfiles y modelos de clasificación como Random Forest para la predicción. Los resultados identifican el perfil dominante del "pragmático crítico", un usuario que valora los beneficios de la IA mientras es agudamente consciente de sus riesgos, y segmentan la población en tres arquetipos (Escéptico, Pragmático Crítico y Tecno-Optimista). Además, se desarrolló un modelo que predice la intención de uso a largo plazo con un 88.1% de exactitud. Se concluye que el estudiantado expresa una demanda clara y transversal por una mayor guía institucional, recomendando a las universidades transitar de una postura reactiva a una estrategia proactiva que fomente un uso crítico y ético.

Palabras Clave: Inteligencia Artificial Generativa, Educación Superior, Percepciones Estudiantiles, Pragmatismo Crítico, Machine Learning.

Abstract

This study addresses the critical gap between the rapid and widespread adoption of generative artificial intelligence by students and the slow response capacity of higher education institutions. To inform the development of effective educational policies and strategies, quantitative research was done using a validated survey given to a sample of 474 university students in Ecuador. Data analysis combined descriptive and inferential statistics with machine learning techniques in Python, including the K-Means clustering algorithm for profile segmentation and classification models such as Random Forest for prediction. The results identify the dominant profile of the "critical pragmatist," a user who values the benefits of AI while being keenly aware of its risks, and segment the population into three archetypes (Skeptic, Critical Pragmatist, and Techno-Optimist). In addition, a model was developed that predicts long-term usage intent with 88.1% accuracy. It is concluded that students express a clear and widespread demand for greater institutional guidance, and it is recommended that universities move from a reactive stance to a proactive strategy that encourages critical and ethical use.

Keywords: Generative Artificial Intelligence, Higher Education, Student Perceptions, Critical Pragmatism, Machine Learning.



<http://www.editorialgrupo-aea.com>



[Editorial Grupo AeA](#)



[editorialgrupoea](#)



[Editorial Grupo AEA](#)

ISBN: 978-9942-651-95-2



9 789942 651952