

UNIVERSIDAD POLITÉCNICA ESTATAL DEL CARCHI

POSGRADO



MAESTRÍA EN ESTADÍSTICA APLICADA

“Evaluación del proceso de aprendizaje con inteligencia artificial: estudio de caso en Instituciones de Educación Superior”

Trabajo de titulación previa la obtención del
Título de Magíster en Estadística Aplicada

Autor: Luis Danilo Flores Rivera

Tutora: Mgtr. Andrea Isabel Freire Pesántez

Tulcán, julio 2025

CERTIFICADO DEL TUTOR

Certifico que el maestrante Flores Rivera Luis Danilo con el número de cédula 1802766897 ha elaborado el trabajo de titulación: “Evaluación del proceso de aprendizaje con inteligencia artificial: estudio de caso en Instituciones de Educación Superior”.

Este trabajo se sujeta a las normas y metodología dispuestas en el Reglamento de la Unidad de Titulación de Postgrado con RESOLUCIÓN No. 183-CSUP-2024, por lo tanto, autorizo su presentación para la sustentación respectiva.

f.....

Mgtr. Andrea Isabel Freire Pesántez

TUTORA

Tulcán, julio de 2025

AUTORÍA DE TRABAJO

El presente trabajo de titulación constituye un requisito previo para la obtención del título de Magíster en Estadística Aplicada.

Yo, Flores Rivera Luis Danilo con cédula de identidad número 1802766897 declaro: que la investigación es absolutamente original, auténtica, personal y los resultados y conclusiones a los que he llegado son de mi absoluta responsabilidad.

f.....

Flores Rivera Luis Danilo

AUTOR

Tulcán, julio de 2025

ACTA DE CESIÓN DE DERECHOS DEL TRABAJO DE TITULACIÓN

Yo, Flores Rivera Luis Danilo declaro ser autor de los criterios emitidos en el trabajo de titulación: “Evaluación del proceso de aprendizaje con inteligencia artificial: estudio de caso en Instituciones de Educación Superior” y eximo expresamente a la Universidad Politécnica Estatal del Carchi y a sus representantes legales de posibles reclamos o acciones legales.

f.....

Flores Rivera Luis Danilo

AUTOR

Tulcán, julio de 2025

AGRADECIMIENTO

A la Universidad Estatal Politécnica del Carchi, por brindarme la oportunidad de desarrollarme en el campo de la Estadística. Su dedicación a la excelencia académica y su compromiso con la formación integral de sus estudiantes han sido fundamentales para mi crecimiento profesional y personal.

Mi más sincero agradecimiento a la Magíster Andrea Freire por su apoyo y dirección que han sido esenciales para alcanzar mis metas y aspiraciones.

Con gratitud,

Luis Danilo Flores Rivera

DEDICATORIA

A mi Dios, que me da las bendiciones y la energía para avanzar cada día. Su presencia es la motivación constante para mi superación personal.

A mi madre Blanquita, que me ilumina desde el cielo, quien dejó en mí muchas enseñanzas y el amor incondicional para ser mejores personas.

A mi padre Luis, a quien tengo la fortuna de tener y que es un constante ejemplo de trabajo y superación, que no ve en su edad un obstáculo para seguir sirviendo y siendo útil a la sociedad.

A Silvana por ser mi compañera, mi amiga y mi amor. Juntos, hemos creado recuerdos inolvidables y sé que aún nos esperan muchos más.

A mi sobrina Samy, le deseo el mayor de los éxitos en su camino hacia la obtención de un título profesional.

ÍNDICE

RESUMEN	xiv
ABSTRACT	xv
CAPÍTULO I	1
PROBLEMA	1
1.1. Planteamiento del problema	1
1.2. Preguntas de investigación o hipótesis	2
1.3. Objetivos de investigación	2
1.3.1. Objetivo General	2
1.3.2. Objetivos Específicos	2
1.4. Justificación	3
CAPÍTULO II	5
FUNDAMENTACIÓN TEÓRICA.....	5
2.1. Antecedentes de investigación.....	5
2.2. Marco teórico	7
2.3. Marco legal	16
CAPÍTULO III	19
METODOLOGÍA	19
3.1. Descripción del área de estudio.....	19
3.2. Enfoque y tipo de investigación	23
3.3. Definición y operacionalización de variables.....	25
3.4. Procedimientos	29
3.5. Consideraciones bioéticas	41
CAPÍTULO IV.....	43
RESULTADOS Y DISCUSIÓN.....	43
4.1. Análisis de los resultados.....	43
4.2. Discusión	86

CONCLUSIONES Y RECOMENDACIONES.....	89
Conclusiones.....	89
Recomendaciones.....	91
REFERENCIAS	94
ANEXOS.....	108

ÍNDICE DE TABLAS

Tabla 1. Operacionalización de las variables	28
Tabla 2. Descripción de la muestra estudiantes y docentes UEP consideraras en el estudio	22
Tabla 3. Características generales de los estudiantes encuestados	44
Tabla 4. Frecuencia de uso de herramientas de IA por estudiantes.....	45
Tabla 5. Codificación de las preguntas y equivalencia escala Likert	45
Tabla 6. Estadísticos descriptivos de las preguntas de escala Likert estudiantes	46
Tabla 7. Prueba Bartlett y KMO datos estudiantes	52
Tabla 8. AFC aplicando criterio ML datos estudiantes	55
Tabla 9. Análisis de confiabilidad de los datos ML_1 de estudiantes	56
Tabla 10. Límites de confianza al 95% para los datos ML_1 de estudiantes	56
Tabla 11. Confiabilidad al descartar un elemento en los datos ML_1 de estudiantes .	57
Tabla 12. Estadísticas de las variables ML_1 de estudiantes	57
Tabla 13. Análisis de confiabilidad de los datos ML_2 de estudiantes	58
Tabla 14. Límites de confianza al 95% para los datos ML_2 de estudiantes	58
Tabla 15. Confiabilidad al descartar un elemento en los datos ML_2 de estudiantes .	59
Tabla 16. Estadísticas de las variables ML_2 de estudiantes	59
Tabla 17. Variables iniciales estimadas para el modelo de RLM	60
Tabla 18. Resumen del modelo completo RLM datos estudiantes.....	61
Tabla 19. Modelo final RLM criterio AIC datos estudiantes	62
Tabla 20. Resumen del modelo final RLM datos estudiantes.....	63
Tabla 21. Uso de la IA en la educación: Razones, Herramientas y Frecuencia datos estudiantes	64
Tabla 22. Características de los docentes encuestados	65
Tabla 23. Utilización de herramientas IA docentes	66
Tabla 24. Estadísticos descriptivos de las preguntas de escala Likert docentes.....	67
Tabla 25. Prueba Bartlett y KMO datos docentes	71
Tabla 26. AFC aplicando criterio ML datos docentes	74
Tabla 27. Análisis de confiabilidad de los datos ML_1 de docentes.....	75
Tabla 28. Límites de confianza al 95% para los datos ML_1 de docentes.....	76
Tabla 29. Confiabilidad al descartar un elemento en los datos ML_1 de docentes.....	76
Tabla 30. Estadísticas de las variables ML_1 de docentes.....	77

Tabla 31. Análisis de confiabilidad de los datos ML ₂ de docentes.....	77
Tabla 32. Límites de confianza al 95% para los datos ML ₂ de docentes.....	78
Tabla 33. Confiabilidad al descartar un elemento en los datos ML ₂ de docentes.....	78
Tabla 34. Estadísticas de las variables ML ₂ de docentes.....	79
Tabla 35. Análisis de confiabilidad de los datos ML ₃ de docentes.....	80
Tabla 36. Límites de confianza al 95% para los datos ML ₃ de docentes.....	80
Tabla 37. Confiabilidad al descartar un elemento en los datos ML ₃ de docentes.....	81
Tabla 38. Estadísticas de las variables ML ₃ de docentes.....	81
Tabla 39. Resumen del modelo completo RLM datos docentes	83
Tabla 40. Modelo final RLM criterio AIC datos docentes.....	83
Tabla 41. Resumen del modelo final RLM datos docentes	84
Tabla 42. Uso de la IA en la educación: Razones, Herramientas y Frecuencia datos docentes	85

ÍNDICE DE FIGURAS

Figura 1. Procesamiento de datos en modelos IAGen.....	10
Figura 2. Mapa de Ecuador con ubicación de las IES Participantes	20
Figura 3. Ruta de la investigación cuantitativa.....	24
Figura 4. Relación de la variable dependiente con la variable independiente	27
Figura 5. Diagrama de caja de las preguntas de escala Likert estudiantes	48
Figura 6. Correlación de Spearman datos estudiantes	48
Figura 7. Normalidad y linealidad datos estudiantes.....	50
Figura 8. Dispersión de las dimensiones datos estudiantes	52
Figura 9. Sedimentación del ACP datos estudiantes	53
Figura 10. Análisis paralelo de factores datos estudiantes	54
Figura 11. Diagrama de caja de las preguntas de escala Likert docentes	68
Figura 12. Correlación de Spearman datos docentes	69
Figura 13. Normalidad y linealidad datos docentes	70
Figura 14. Dispersión de las dimensiones datos docentes	71
Figura 15. Sedimentación del ACP datos docentes.....	72
Figura 16. Análisis paralelo de factores datos docentes	73

ÍNDICE DE ECUACIONES

Ecuación (1) Prueba de Kaiser-Meyer-Olkin	35
Ecuación (2) Regresión Lineal Múltiple	36
Ecuación (3) Análisis de Componentes Principales	37
Ecuación (4) Distancia Euclidiana.....	37

ÍNDICE DE ANEXOS

Anexo A. Certificado del abstract por parte de idiomas	108
Anexo B. Cuestionario	109

RESUMEN

El uso de la Inteligencia Artificial en la Educación Superior presenta oportunidades significativas para mejorar el aprendizaje al identificar patrones en el rendimiento estudiantil y tomar decisiones informadas. Sin embargo, el desconocimiento puede generar riesgos, como la falta de pensamiento crítico y una excesiva dependencia tecnológica. El objetivo de la investigación fue evaluar el impacto del uso de la inteligencia artificial en el proceso de aprendizaje, de enfoque cuantitativo y corte transversal, se llevó a cabo en siete Instituciones de Educación Superior del Ecuador, durante el semestre octubre 2024 - marzo 2025. Se aplicó un cuestionario a 489 estudiantes y 83 docentes, se empleó un Análisis Factorial Exploratorio para identificar la estructura subyacente de variables y Regresión Lineal Múltiple, para modelar comportamientos complejos. Los resultados revelaron una alta valoración del potencial de estas herramientas para personalizar la enseñanza y mejorar la comprensión de los contenidos. Se identificó la necesidad de una mayor capacitación en el uso de estas tecnologías y de establecer normas éticas claras para su aplicación. Aunque el estudio se centró en la percepción de los estudiantes, futuras investigaciones podrían explorar el impacto de la Inteligencia Artificial en variables como el rendimiento académico y la equidad educativa.

Palabras clave: Enseñanza superior; estadísticas educacionales; ética de la tecnología; inteligencia artificial; proceso de aprendizaje.

ABSTRACT

The use of Artificial Intelligence in Higher Education presents significant opportunities to improve learning by identifying patterns in student performance and making informed decisions. However, ignorance can generate risks, such as a lack of critical thinking and excessive technological dependence. The objective of the research was to evaluate the impact of the use of artificial intelligence on the learning process, with a quantitative and cross-sectional approach, carried out in seven Higher Education Institutions in Ecuador, during the semester October 2024 - March 2025. A questionnaire was administered to 489 students and 83 teachers, an Exploratory Factor Analysis was employed to identify the underlying structure of variables, and Multiple Linear Regression was used to model complex behaviors. The results revealed a high appreciation for the potential of these tools to personalize teaching and improve content comprehension. The need for greater training in the use of these technologies and the establishment of clear ethical standards for their application was identified. Although the study focused on students' perceptions, future research could explore the impact of Artificial Intelligence on variables such as academic performance and educational equity.

Keywords: Higher education; educational statistics; technology ethics; artificial intelligence; learning process.

CAPÍTULO I

PROBLEMA

1.1. Planteamiento del problema

La disrupción y transformación tecnológica digital ha generado cambios significativos en la humanidad. En este sentido, la Inteligencia Artificial (IA), es el protagonista emergente que genera nuevos escenarios en las actividades de las personas, entidades y organizaciones. Los procesos educativos no son la excepción puesto que la IA en el aprendizaje es un nuevo factor que produce una incertidumbre en el contexto académico (Maldonado Zuñiga *et al.*, 2023; Fajardo Aguilar *et al.*, 2023).

La IA puede incidir en el proceso de aprendizaje generando riesgos por un mal uso y/o desconocimiento de la herramienta tecnológica; es decir, su implicación, puede centrarse a la falta de comprensión y adiestramiento de la IA. Otro factor, es la dependencia tecnológica que denota una excesiva confianza a la IA; esto se refleja cuando no se contrasta o revisa contenidos creados por IA ocasionando errores o mal entendidos, dando muestras de falta de habilidades del pensamiento crítico (Beneite-Martí, 2023; Delgado *et al.*, 2024).

De manera opuesta, la no utilización de la IA en la Educación Superior puede ser otro de los problemas en la evaluación del rendimiento académico como no identificar la ineficiencia en los procesos evaluativos por no reconocer patrones y/o tendencias, atención oportuna en el rendimiento de los estudiantes, falta de acción en la toma de decisiones institucionales entre otros posibles escenarios. Por tanto, no integrar IA en la gestión académica puede crear sesgos e inconsistencias en el rendimiento del estudiante (Jimbo-Santana *et al.*, 2023).

Por otra parte, la falta de responsabilidad y ética en el manejo de la IA puede afectar gravemente la privacidad y la transparencia. Por ende, la necesidad de prácticas rigurosas y responsables, así como de regulaciones de la IA respaldadas por análisis estadísticos, permitirá una mejor toma de decisiones. (Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura [UNESCO], 2021).

Este estudio de caso se llevó a cabo en diversas Instituciones de Educación Superior (IES) de Ecuador durante el semestre octubre 2024 - marzo 2025, con la participación voluntaria de estudiantes y docentes. Al involucrar a varias IES del país, se contextualizan los efectos del uso de la IA en el aprendizaje universitario y se proponen recomendaciones adaptadas a realidades institucionales específicas.

En resumen, el problema de investigación se plantea de la siguiente manera: ¿Cómo afecta el uso de la IA en el proceso de aprendizaje de estudiantes de Educación Superior en Ecuador durante el semestre de octubre 2024 a marzo 2025, en el contexto de un estudio de caso realizado en diversas instituciones del país?

1.2. Preguntas de investigación o hipótesis

¿Cómo afecta el uso de la IA en el proceso de aprendizaje de los estudiantes de las IES participantes en el estudio de caso?

¿Cómo perciben dichos estudiantes su satisfacción con el aprendizaje mediado por IA?

¿Cuál es el nivel de confianza que tienen los estudiantes en los resultados proporcionados por la IA en sus actividades académicas?

¿Cómo valoran éticamente los estudiantes participantes el uso de la IA en el contexto de sus IES?

1.3. Objetivos de investigación

1.3.1. Objetivo General

Evaluar el impacto del uso de herramientas de Inteligencia Artificial en el proceso de aprendizaje de los estudiantes de Instituciones de Educación Superior en Ecuador, durante el semestre octubre 2024 – marzo 2025.

1.3.2. Objetivos Especificos

- Analizar la percepción de los estudiantes sobre su nivel de satisfacción con el aprendizaje mediado por Inteligencia Artificial, considerando indicadores como la

comprensión de contenidos y el desarrollo de habilidades cognitivas, durante el semestre octubre 2024 – marzo 2025.

- Determinar el nivel de confianza que los estudiantes depositan en los resultados generados por herramientas de Inteligencia Artificial en el contexto de sus actividades académicas, durante el semestre octubre 2024 – marzo 2025.
- Analizar la apreciación ética de los estudiantes respecto al uso de la Inteligencia Artificial en el entorno educativo, valorando aspectos como la privacidad, la transparencia y el respeto a los derechos humanos, durante el semestre octubre 2024 – marzo 2025.

1.4. Justificación

La IA está experimentando un crecimiento acelerado que anticipa un futuro educativo con mayor presencia en las IES. Las aplicaciones de IA se desarrollan e implementan para mejorar la atención y el servicio en el ámbito educativo, apoyando actividades académico-administrativas que optimizan los Procesos de Enseñanza-Aprendizaje (PEA). Este cambio de paradigma, impulsado por la transformación digital, permite a varias IES crear procesos más eficientes y adaptados a las necesidades de la comunidad educativa (Rock Content, 2020; Rivas *et al.*, 2023; Jimbo-Santana *et al.*, 2023).

Esta investigación se alinea con el Objetivo de Desarrollo Sostenible (ODS) 4 de las Naciones Unidas, que busca "*garantizar una educación inclusiva, equitativa y de calidad y promover oportunidades de aprendizaje durante toda la vida para todos*" (Organización de las Naciones Unidas [ONU], 2015). Asimismo, se enmarca en la línea de investigación del programa, que promueve el uso de tecnologías emergentes para mejorar la calidad educativa y fomentar la innovación en los procesos de enseñanza-aprendizaje.

En el ámbito nacional, el estudio aporta al Objetivo 2 del Plan Nacional de Desarrollo para el Nuevo Ecuador 2024-2025, el cual enfatiza en el fortalecimiento de la Educación Superior y la integración de tecnologías emergentes para el desarrollo sostenible del país

(Secretaría Nacional de Planificación, 2024). Al analizar la eficacia de la IA en las IES, se proporciona insumos clave para la formulación de políticas y estrategias que impulsen la transformación digital en la Educación Superior del Ecuador.

Comprender el impacto de la IA es fundamental para determinar cómo puede contribuir a personalizar el aprendizaje y potenciar las habilidades críticas de los estudiantes. Implementar sistemas de IA en las IES requiere analizar su eficacia y repercusiones en la experiencia educativa. En este sentido, la regresión estadística se presenta como una técnica adecuada para estimar y modelar el proceso de aprendizaje mediado por IA, permitiendo identificar relaciones significativas entre variables clave. Esto proporciona a docentes, investigadores, directivos e instituciones educativas una base sólida para tomar decisiones informadas que mejoren los PEA.

La IA ofrece la posibilidad de personalizar el aprendizaje, adaptando contenidos y actividades a las necesidades individuales y ritmos de cada estudiante, y proporcionando retroalimentación inmediata sobre su progreso (López López *et al.*, 2023). Esto puede incrementar la motivación y el compromiso de los estudiantes, factores esenciales para el éxito académico.

La investigación también aborda las preocupaciones éticas asociadas al uso de la IA en educación. Es crucial investigar la percepción de los estudiantes sobre la confianza y la ética en el uso de estas herramientas, para asegurar que su implementación respete principios fundamentales como la privacidad, la transparencia y la equidad (UNESCO, 2021). Al explorar estas dimensiones, el estudio contribuye a promover prácticas responsables y sostenibles en la adopción de tecnologías emergentes en el ámbito educativo.

Finalmente, este estudio proporcionará información valiosa que podrá ser utilizada para mejorar la implementación de la IA en las IES donde se llevó a cabo la investigación, al identificar prácticas efectivas y áreas de mejora. Los hallazgos permitirán orientar políticas y estrategias institucionales, fomentando una adopción de la IA que maximice beneficios y minimice riesgos para los estudiantes y la comunidad educativa en general (UNESCO, 2023). De esta manera, se refuerza el compromiso con el ODS 4 y se promueve el avance hacia una educación de calidad en Ecuador, en consonancia con las metas establecidas en el Plan Nacional de Desarrollo.

CAPÍTULO II

FUNDAMENTACIÓN TEÓRICA

2.1. Antecedentes de investigación

La transformación digital es el proceso disruptivo tecnológico que vive la sociedad actual, generando cambios continuos y dinámicos que abordan el contexto educativo. En este sentido, su estudio implica tecnología, digitalización, metodologías formativas y diseño de modelos educativos que se caracterizan por la flexibilidad en la enseñanza y aprendizaje. No obstante, estos procesos que hoy en día promueven innovación y automatización integran el uso de IA, de manera imperceptible o visible (Rivas *et al.*, 2023). Al hablar de IA de forma visible es interactuar con programas u asistentes virtuales que se conoce como Inteligencia Artificial Generativa (IAGen) (Puertas, 2023).

La IA se determina como un sistema informático capaz de realizar tareas asociadas con la inteligencia humana, como es la del aprendizaje y la resolución de problemas. Asimismo, la IA presenta en su desarrollo desafíos técnicos y éticos, pero igualmente ofrece oportunidades para mejorar el análisis educativo y personalizar el aprendizaje (Instituto Nacional de Tecnologías Educativas y de Formación del Profesorado [INTEF], 2019).

La IA está redefiniendo el futuro de la Educación Superior al anticipar cambios en el PEA. Es decir, su influencia conlleva una transformación cada vez más personalizada con recursos interactivos y retroalimentación oportuna favoreciendo capacidades y habilidades requeridas en el ambiente educativo y por ende la sociedad (González-González, 2023). A medida que la IA se integre más en la vida de las personas, las instituciones educativas deben estar preparadas ante este desafío que conlleva su aplicación. En tal sentido, la implementación de la IA posibilita a las IES ser más competitivas con recursos didácticos y aplicaciones que favorecen la alta calidad en la enseñanza (Peñaherrera Acurio *et al.*, 2022).

Según Ramos Armijos *et al.*, (2024) la IA permanentemente optimiza su capacidad analítica para la evaluación educativa permitiéndole tener un mayor protagonismo en el PEA (Tomalá De La Cruz *et al.*, 2023). Por tal motivo, el rol del docente se redefine porque la IA automatiza y agiliza tareas favoreciendo con más tiempo al docente y esto puede ser aprovechado en el desarrollo de nuevos enfoques pedagógicos; personalización del aprendizaje con ajuste de contenidos a necesidades individuales; análisis de datos para decisiones educativas informadas que mejoren el rendimiento académico; innovación de la enseñanza con herramientas interactivas entre otros procesos educativos (Pearson, 2023; Flores-Rivera y Meléndez-Tamayo, 2024).

Los docentes valoran las ventajas de integrar IA en el PEA. Estos beneficios incluyen incremento de la motivación, desarrollo de habilidades relacionadas con la solución de problemas y estímulo de la creatividad. Todos estos factores contribuyen a un aprendizaje significativo y enriquecedor (Ayuso del Puerto y Gutiérrez Esteban, 2022). Cabe resaltar que la implementación de IA necesita de estrategias y competencias digitales docentes que apoyen el desarrollo educativo fortaleciendo el enfoque innovador y eficaz del PEA (Carbonell-García *et al.*, 2023; Flores-Rivera y Meléndez-Tamayo, 2024).

Se debe agregar que las IES tienen un interés particular en identificar factores, variables o características claves que afectan al rendimiento académico con el fin de tomar decisiones que beneficien oportunamente y mejoren los resultados de aprendizaje de los estudiantes (Rico Páez y Gaytán Ramírez, 2022).

Un aspecto por considerar es la preocupación ética en los sistemas de IA, originada por la deshonestidad de su utilización y protección de datos (Fajardo Aguilar *et al.*, 2023). En este orden de ideas, la IA presenta varios desafíos éticos tal como sesgo y discriminación, privacidad y protección de datos, transparencia y comprensibilidad, impacto social y laboral, autonomía (UNESCO, 2023; Historioteca, 2023; Ramos, 2024). Por tal motivo, se busca asegurar que la implementación de la IA sea de forma responsable y beneficiosa en todo el entorno educativo (Fajardo Aguilar *et al.*, 2023).

Por consiguiente, los estudios previamente expuestos han influenciado de manera decisiva la orientación y el diseño metodológico de la presente investigación. La

evidencia sobre la transformación digital y la integración de la IA en el ámbito educativo (Rivas *et al.*, 2023; Puertas, 2023) ha permitido identificar la necesidad de innovar en las metodologías formativas, mientras que los análisis que destacan la personalización del aprendizaje y la mejora en el rendimiento académico (González-González, 2023; Peñaherrera Acurio *et al.*, 2022; Pearson, 2023) han facilitado la selección de variables críticas para evaluar el impacto de la IA en el proceso educativo. Asimismo, las preocupaciones éticas referentes a la protección de datos y la transparencia (Fajardo Aguilar *et al.*, 2023; UNESCO, 2023; Historioteca, 2023; Ramos, 2024) han orientado la adopción de estrategias metodológicas responsables que aseguren un análisis riguroso. En conjunto, estos antecedentes no solo enriquecen el marco teórico, sino que también han sido determinantes para la definición de objetivos, la elección de los instrumentos de medición y el desarrollo de enfoques analíticos aplicables al contexto de las IES ecuatorianas.

2.2. Marco teórico

La creciente presencia de la IA en diversos ámbitos de la sociedad ha generado transformaciones significativas, particularmente en la Educación Superior. Para comprender el efecto del uso de la IA en el proceso de aprendizaje de los estudiantes, es esencial explorar los conceptos fundamentales de la IA, sus métodos y técnicas, su aplicación en el ámbito educativo y las implicaciones éticas asociadas.

La IA y sus fundamentos

La IA es un campo científico que implica la creación de computadores y máquinas capaces de razonar, aprender y actuar, emulando aspectos del comportamiento de la inteligencia humana. Los avances constantes en la IA han contribuido significativamente a la transformación digital, evidenciados en la optimización de algoritmos lógicos, velocidades de procesamiento y capacidades en el manejo de datos. Estos avances superan las capacidades de análisis humanas y ayudan en la toma de decisiones basadas en patrones generales (Ávila-Tomás *et al.*, 2020; Franganillo, 2023; Google Cloud, 2024).

La comprensión de estos fundamentos es crucial para analizar el efecto del uso de la IA en el proceso de aprendizaje, ya que permite identificar cómo estas tecnologías pueden mejorar o dificultar el aprendizaje de los estudiantes.

Métodos y técnicas de la IA

La IA se centra en el desarrollo de sistemas capaces de optimizar y personalizar los procesos educativos. En este contexto, se emplean diversas técnicas que no solo facilitan la personalización del aprendizaje, sino que también permiten un seguimiento académico detallado y la creación de herramientas que influyen en la satisfacción y el nivel de confianza de los estudiantes respecto a los resultados proporcionados por la IA.

- **Resolución de Problemas y Búsqueda:** Los algoritmos de optimización y búsqueda permiten identificar soluciones y anticipar dificultades. En el medio académico, estos métodos se utilizan para detectar patrones que indiquen un posible descenso en el rendimiento o riesgo de deserción, facilitando intervenciones tempranas a través de sistemas de alerta y análisis predictivos (Romero y Ventura, 2020).
- **Sistemas Basados en el Conocimiento:** Se emplean reglas lógicas y estructuras de datos que conforman entornos de tutoría y apoyo formativo. Estos sistemas integran información diagnóstica actualizada para monitorear el progreso estudiantil, posibilitando la adaptación de estrategias pedagógicas y la toma de decisiones fundamentada en datos precisos (VanLehn, 2011).
- **Aprendizaje Automático (*Machine Learning*):** Al entrenarse con datos históricos y en tiempo real, estos algoritmos identifican patrones de aprendizaje individuales. Esta capacidad permite personalizar contenidos, detectar a tiempo a estudiantes en riesgo y ajustar dinámicas formativas de manera proactiva, fortaleciendo así el seguimiento académico (Gašević *et al.*, 2015).
- **Inteligencia Artificial Distribuida:** Mediante la colaboración entre múltiples agentes y sistemas, se logra la integración de datos multidimensionales en tiempo

real para abordar problemas complejos. Este enfoque favorece la coordinación de intervenciones y la creación de entornos colaborativos, lo que resulta clave para un seguimiento académico integral y conectado (Torra i Reventós, 2019; Chen *et al.*, 2020).

La integración de estas técnicas y métodos constituye el soporte fundamental para desarrollar herramientas educativas que influyen directamente en la percepción de los estudiantes. Dichas aplicaciones no solo mejoran la satisfacción con el aprendizaje mediado por IA, sino que también fortalecen el nivel de confianza en los resultados que estos sistemas proporcionan.

Estudios recientes han demostrado que el diseño de interfaces intuitivas y el análisis predictivo en tiempo real incrementan la aceptación y el compromiso estudiantil, generando un impacto positivo en el rendimiento académico y en la confianza en la tecnología educativa (Maluenda Albornoz *et al.*, 2021; Cobo-Rendón *et al.*, 2022). Asimismo, la evolución de la IA aplicada a la educación plantea interrogantes sobre la dependencia de los sistemas automatizados y su influencia en el desarrollo de habilidades de pensamiento crítico y autonomía de aprendizaje (Marimon *et al.*, 2025; Loján *et al.*, 2025).

Inteligencia Artificial Generativa (IAGen)

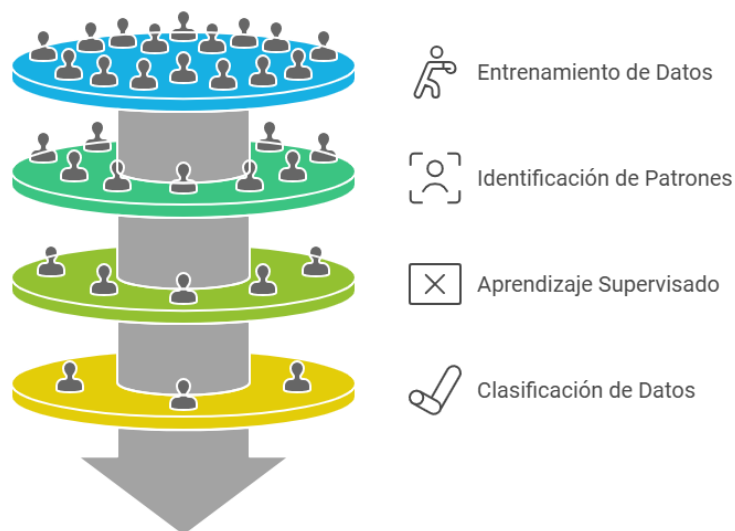
La IAGen es una rama de la IA que genera nuevo contenido digital, como texto, imágenes, música, audio, vídeos y código de software, en respuesta a instrucciones en lenguaje natural denominadas *prompts* (Fengchun y Wayne, 2024; Google Cloud, 2024). En el contexto educativo, la IAGen puede ser utilizada para crear materiales de aprendizaje personalizados, generar ejercicios y brindar retroalimentación inmediata, impactando directamente en el proceso de aprendizaje de los estudiantes y en su satisfacción con el uso de estas herramientas.

La IAGen se entrena utilizando modelos de aprendizaje automático basados en grandes conjuntos de datos obtenidos de diversas fuentes. Las técnicas empleadas analizan e identifican patrones que permiten generar contenido coherente y relevante. Esto es fundamental para entender cómo afecta el uso de la IA en el proceso de

aprendizaje y el nivel de confianza que tienen los estudiantes en los resultados. (Ver Figura 1).

Figura 1

Procesamiento de datos en modelos IAGen



Nota. Procesamiento de datos en modelos IAGen. Reimpreso de Napkin AI (2024).

IA en la Educación Superior

La aplicación de la IA en la Educación Superior está transformando radicalmente los PEA. Gracias a algoritmos avanzados y técnicas de análisis de datos, la IA permite personalizar el aprendizaje mediante la adaptación de contenidos y metodologías pedagógicas a las necesidades específicas de cada estudiante, lo que se traduce en entornos virtuales más amigables, interactivos y motivadores (Tomalá De La Cruz *et al.*, 2023). Tal personalización no solo incrementa el compromiso y la participación estudiantil, sino que también contribuye a la detección temprana de dificultades, permitiendo intervenciones oportunas que favorecen el éxito académico.

Además, la integración efectiva de la IA en IES implica una reestructuración de modelos pedagógicos y administrativos. Los sistemas basados en IA se utilizan en tutorías virtuales, elaboración y actualización de contenidos, asistencia en tiempo real,

y en la administración de recursos didácticos, facilitando la toma de decisiones mediante el manejo y análisis de grandes volúmenes de datos. Estas tecnologías potencian el rendimiento institucional y la competitividad al ofrecer procesos educativos de alta calidad y adaptados a la era digital (Peñaherrera Acurio *et al.*, 2022). Asimismo, autores como Salmerón Moreira *et al.* (2023) advierten que para que estas aplicaciones sean realmente efectivas, se requiere un enfoque multidisciplinario que articule innovaciones tecnológicas con estrategias pedagógicas y una gestión cuidadosa de los riesgos inherentes al manejo de información sensible. En este sentido, la adecuada gobernanza de los datos académicos y la formación continua del personal docente se convierten en elementos clave que deben reforzarse para garantizar una implementación integral y sostenible de la tecnología en el ámbito universitario.

Ética en la IA

El despliegue de la IA en la Educación Superior abre un amplio espectro de interrogantes éticos que abarcan todas las etapas de su ciclo de vida: desde el diseño, pasando por la implementación, hasta la evaluación continua de estos sistemas. Los algoritmos utilizados en la IA pueden reproducir o incluso amplificar sesgos existentes, lo cual pone en riesgo la equidad y la justicia en los procesos de evaluación y toma de decisiones. Además, la utilización intensiva de datos académicos requiere establecer protocolos robustos que aseguren el consentimiento informado, la protección de la privacidad y la seguridad de la información de estudiantes y docentes (UNESCO, 2021).

Durante la implementación de estudios y sistemas basados en IA, es indispensable considerar no solo las implicaciones técnicas, sino también las consecuencias sobre la comunidad educativa. Así como, la recopilación y el análisis de datos académicos sin las debidas garantías pueden vulnerar derechos fundamentales y favorecer prácticas discriminatorias. En este contexto, Salmerón Moreira *et al.* (2023) enfatizan la importancia de establecer marcos regulatorios y estrategias de gobernanza que aseguren la transparencia y rendición de cuentas en el uso de la IA. Estos mecanismos deben contemplar la eliminación de sesgos mediante auditorías regulares, la adaptación de normativas de protección de datos y la participación activa

de todos los actores involucrados en el proceso educativo, promoviendo así un entorno inclusivo y ético en el que la innovación tecnológica se aplique de manera responsable.

Procesos de aprendizaje en la era de la IA

Los procesos de aprendizaje son actividades dinámicas de construcción del conocimiento que se desarrollan a lo largo de la vida, y cuyo objetivo es la creación de experiencias significativas (Psise, 2023; Novella García, 2023). En este contexto de transformación digital, la educación moderna debe adaptarse para promover una visión crítica y una praxis transformadora. Por ello, el PEA debe innovar, fomentando la independencia, el protagonismo del estudiante y el pensamiento crítico. De igual forma, es fundamental que las IES perfeccionen sus prácticas pedagógicas y didácticas para impulsar el autoaprendizaje y la creatividad (Tinoco-Izquierdo y Tinoco-Cuenca, 2018).

Dentro de este marco, se emplean una serie de procesos y estrategias que aprovechan las capacidades de la IA para personalizar y optimizar el aprendizaje:

- **Aprendizaje adaptativo y personalizado:** Mediante el uso de algoritmos que analizan datos individuales en tiempo real, es posible ajustar el contenido, la metodología y la dificultad de los materiales de aprendizaje de acuerdo con las necesidades de cada estudiante. Este enfoque, respaldado por Luckin *et al.* (2016) y Genuine Digital School (2024), mejora el rendimiento académico al proporcionar rutas de aprendizaje personalizadas y recursos complementarios.
- **Simulaciones y entornos virtuales inmersivos:** La implementación de tecnologías como la realidad virtual y aumentada permite crear simulaciones que replican situaciones del mundo real. Estas herramientas favorecen la aplicación práctica y el desarrollo de habilidades en entornos seguros, como lo evidencian investigaciones recientes (Zawacki-Richter *et al.*, 2019; Aragón, 2023).
- **Tutorías inteligentes y retroalimentación inmediata:** Sistemas automatizados de tutoría, apoyados en técnicas de aprendizaje automático y análisis predictivo,

brindan a los estudiantes retroalimentación oportuna y personalizada. Este sistema de apoyo, destacado por Baker y Inventaris (2014) y Genuine Digital School (2024), permite identificar áreas de mejora y sugerir recursos adicionales, fortaleciendo el proceso de autoaprendizaje.

- **Gamificación e interactividad:** La incorporación de elementos lúdicos en plataformas educativas (por ejemplo, desafíos, recompensas y competencias) estimula la motivación y la participación activa de los estudiantes. Las estrategias de gamificación han demostrado aumentar el compromiso y consolidar los conocimientos en diversos estudios (Psise, 2023; Novella García, 2023).
- **Ambientes colaborativos y redes de aprendizaje:** Las plataformas digitales permiten la consolidación de comunidades de aprendizaje que facilitan el intercambio de ideas y el trabajo en equipo. Esta interactividad fomenta la co-construcción del conocimiento y el aprendizaje social, como se respalda en estudios de Tinoco-Izquierdo y Tinoco-Cuenca (2018) y Selwyn (2019).

La implementación de estas estrategias no solo potencia el aprendizaje, sino que también facilita la labor docente, al ofrecer herramientas para el seguimiento en tiempo real y la evaluación automatizada del progreso académico. Estas metodologías innovadoras permiten a las IES preparar profesionales que aprenden de manera continua y proactiva, enfrentando los retos y aprovechando las oportunidades que la era de la IA presenta (Aragón, 2023; Genuine Digital School, 2024).

Uso de métodos estadísticos en investigación educativa

El uso de métodos estadísticos es fundamental en la investigación educativa, ya que permite analizar e interpretar fenómenos asociados al aprendizaje y la enseñanza a partir de datos cuantitativos. Estas técnicas posibilitan la identificación de patrones, el establecimiento de relaciones causales y la realización de predicciones que respaldan la toma de decisiones y el diseño de políticas educativas (Cohen *et al.*, 2018).

Modelos y técnicas estadísticas clave

- **Regresión Lineal Simple y Múltiple:** Estos modelos se aplican para estudiar la relación entre una variable dependiente (por ejemplo, el rendimiento académico) y una o más variables independientes como el uso de la IA, la satisfacción con el aprendizaje o la confianza en las herramientas tecnológicas. La aplicación de la regresión requiere verificar supuestos (linealidad, homocedasticidad, normalidad e independencia de los residuos), lo que garantiza la validez de las predicciones (Field, 2018; Cohen *et al.*, 2018).
- **Regresión Logística:** Cuando la variable de interés es dicotómica (por ejemplo, aprobación/reprueba), la regresión logística se utiliza para evaluar la probabilidad de ocurrencia de un evento en función de las variables predictoras. Este modelo permite interpretar el impacto de cada predictor sobre la probabilidad de resultados exitosos o adversos (Hosmer *et al.*, 2013).
- **Modelos de Ecuaciones Estructurales (SEM):** El SEM es una técnica avanzada que permite analizar simultáneamente múltiples relaciones, integrando variables observables y latentes. Se utiliza para explorar constructos complejos como la satisfacción, la confianza y la apreciación ética en contextos educativos, permitiendo la inclusión de variables mediadoras y moderadoras (Hernández Sampieri y Mendoza Torres, 2018; Kline, 2023).
- **Análisis Factorial Exploratorio y Confirmatorio:** Estas técnicas permiten identificar y validar la estructura subyacente de instrumentos de medición, comprobando que las escalas empleadas reflejen adecuadamente los constructos teóricos (Byrne, 2012; Hernández Sampieri y Mendoza Torres, 2018).
- **Análisis de Varianza (ANOVA):** El ANOVA se utiliza para comparar medias entre dos o más grupos, lo cual es esencial al evaluar el impacto de intervenciones educativas, como la implementación de la IA, en diferentes contextos o poblaciones estudiantiles (Tabachnick y Fidell, 2013).

- **Modelos de Regresión Jerárquica o Multinivel (HLM):** Estos modelos son apropiados cuando los datos presentan una estructura anidada (por ejemplo, estudiantes agrupados en aulas o centros educativos), permitiendo separar efectos a nivel individual y grupal, lo que facilita la comprensión de cómo el contexto influye en los resultados académicos (Raudenbush y Bryk, 2002).

La correcta aplicación de estos modelos requiere la implementación de estrategias metodológicas rigurosas:

- **Recopilación y limpieza de datos:** Se diseñan instrumentos de recolección (cuestionarios, registros institucionales, bases de datos digitales) y se aplican técnicas de limpieza y normalización para garantizar que la información sea fiable y apta para el análisis (Cohen *et al.*, 2018).
- **Análisis exploratorio de datos (AED):** Previo a la modelación, se realizan análisis descriptivos que permiten examinar la distribución, tendencia central y dispersión de las variables, identificar valores atípicos y evaluar relaciones preliminares (Field, 2013).
- **Construcción y validación del modelo:** Consiste en seleccionar el modelo adecuado, evaluar los supuestos, ajustar parámetros mediante validación cruzada y analizar los residuos, lo que permite interpretar con rigor los coeficientes y establecer la relevancia de cada predictor (Hosmer *et al.*, 2013; Kline, 2023).
- **Interpretación y aplicación práctica de los resultados:** Los hallazgos se utilizan para evaluar el impacto de intervenciones como la implementación de la IA en el PEA identificar factores predictivos del éxito académico y explorar las relaciones complejas entre múltiples variables, lo que proporciona una base sólida para futuras políticas y estrategias educativas (Hernández Sampieri y Mendoza Torres, 2018).

En el marco de esta investigación, el uso de técnicas como la regresión lineal múltiple, el análisis factorial exploratorio y el confirmatorio permitirá examinar cuantitativamente el impacto de la IA en el proceso de aprendizaje. Además, se analizará cómo variables

como la satisfacción, la confianza y la apreciación ética inciden en el rendimiento académico, proporcionando una visión integral de la problemática estudiada.

2.3. Marco legal

El estudio sobre la evaluación del proceso de aprendizaje con inteligencia artificial: estudio de caso en Instituciones de Educación Superior se fundamenta en un conjunto de normativas y regulaciones que garantizan el uso ético, responsable y seguro de las tecnologías emergentes en el ámbito educativo.

La Constitución ecuatoriana 2008, establece principios fundamentales relacionados con el derecho a la educación, el acceso a la tecnología y el desarrollo científico. En el Artículo 26, se reconoce la educación como un derecho de las personas y un deber ineludible del Estado, orientado al desarrollo integral de individuos y colectividades. Además, el Artículo 16 garantiza el acceso universal a las Tecnologías de Información y Comunicación (TIC), promoviendo su uso para el desarrollo social, cultural, económico, educativo y político. Asimismo, el Artículo 387 indica que el Estado promoverá el desarrollo de la ciencia, tecnología, innovación y saberes ancestrales, garantizando la libertad de creación e investigación (Asamblea Nacional, 2008).

La Ley Orgánica de Educación Superior (LOES) 2010, regula el funcionamiento de las IES en Ecuador y establece lineamientos para mejorar la calidad educativa. Los Artículos 84 y 85 fomentan la incorporación de TIC en los procesos académicos, promoviendo la innovación y la mejora continua. Además, el Artículo 169 impulsa la investigación científica y tecnológica como función sustantiva de las IES, incentivando proyectos que contribuyan al desarrollo nacional (Asamblea Nacional, 2010).

Código Orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación (Código Ingenios) 2016, este código regula aspectos relacionados con la ciencia, tecnología, innovación y transferencia de conocimientos. Los Artículos 144 y 145 promueven el acceso abierto a los resultados de investigaciones financiadas con recursos públicos, democratizando la información científica y tecnológica. El Artículo 197 establece principios éticos para la investigación científica, garantizando el respeto a los derechos humanos y la protección de datos personales. Además, los Artículos

83 y 84 reglamentan el tratamiento y protección de datos personales en actividades de investigación, asegurando su confidencialidad y uso adecuado (Asamblea Nacional, 2016).

Ley Orgánica de Protección de Datos Personales 2021, es fundamental en el contexto del uso de IA en la educación. La ley exige el consentimiento informado para el tratamiento de datos personales (Artículo 7) y establece principios como legalidad, transparencia, confidencialidad y seguridad en el manejo de datos (Artículos 25-31). Además, reconoce derechos de los titulares de los datos como acceso, rectificación, eliminación y oposición al tratamiento de sus datos (Artículos 62-70) (Asamblea Nacional, 2021).

Normativa del Consejo de Educación Superior (CES) 2019, emite regulaciones y directrices para las IES. El Reglamento de Régimen Académico establece lineamientos para asegurar la calidad de la formación académica, incluyendo la integración de tecnologías en los procesos educativos y la promoción de metodologías innovadoras. Asimismo, la Política de Integridad Académica promueve la ética y la integridad en las actividades académicas y de investigación, abordando temas como el plagio y el uso responsable de la información (CES, 2019).

Recomendación sobre la Ética de la IA de la UNESCO 2021, aunque no es una normativa nacional, Ecuador, como Estado miembro de la UNESCO, se alinea con las recomendaciones internacionales en materia de IA. La UNESCO enfatiza que los sistemas de IA deben respetar los derechos humanos, la inclusión, la diversidad y promover el bienestar común. Se destaca la necesidad de desarrollar marcos legales y políticas que garanticen el uso ético y responsable de la IA en todos los sectores, incluida la educación (UNESCO, 2021).

Plan Nacional de Desarrollo para el Nuevo Ecuador 2024-2025, aporta al Objetivo 2 que enfatiza el fortalecimiento de la Educación Superior y la integración de tecnologías emergentes para el desarrollo sostenible del país (Secretaría Nacional de Planificación, 2024). Promueve la adopción de tecnologías como la IA para mejorar la calidad educativa, innovar en metodologías de enseñanza y fomentar el desarrollo de competencias digitales en los estudiantes.

El estudio también se alinea con el ODS 4 de las Naciones Unidas, que busca "*garantizar una educación inclusiva, equitativa y de calidad y promover oportunidades de aprendizaje durante toda la vida para todos*". La Meta 4.4 apunta a aumentar el número de jóvenes y adultos con competencias técnicas y profesionales, incluyendo habilidades necesarias para el acceso a empleos de calidad y emprendimiento (ONU, 2015).

En tal sentido, el conjunto normativo vigente en Ecuador respalda de manera contundente la investigación sobre el uso de la IA en la Educación Superior, al establecer un entorno regulatorio que equilibra la innovación tecnológica con la protección de los derechos individuales y colectivos. En efecto, la Constitución y normativas específicas como la LOES y el Código Orgánico de la Economía Social de los Conocimientos garantizan el acceso a las TIC y fomentan la investigación y el desarrollo científico, sentando las bases para la implementación de tecnologías emergentes con un compromiso ético y responsable. Además, la Ley de Protección de Datos Personales refuerza el uso ético de la IA al exigir un tratamiento cuidadoso y seguro de la información, mientras que las directrices internacionales, como las recomendaciones de la UNESCO, complementan este marco al promover un uso inclusivo y respetuoso de los sistemas automatizados en el ámbito educativo. En conjunto, estas normativas no solo aseguran la integridad y la transparencia en los procesos académicos, sino que también impulsan la relevancia de la investigación, garantizando que la incorporación de la IA se realice bajo estrictos estándares de calidad, equidad y sostenibilidad.

CAPÍTULO III

METODOLOGÍA

3.1. Descripción del área de estudio

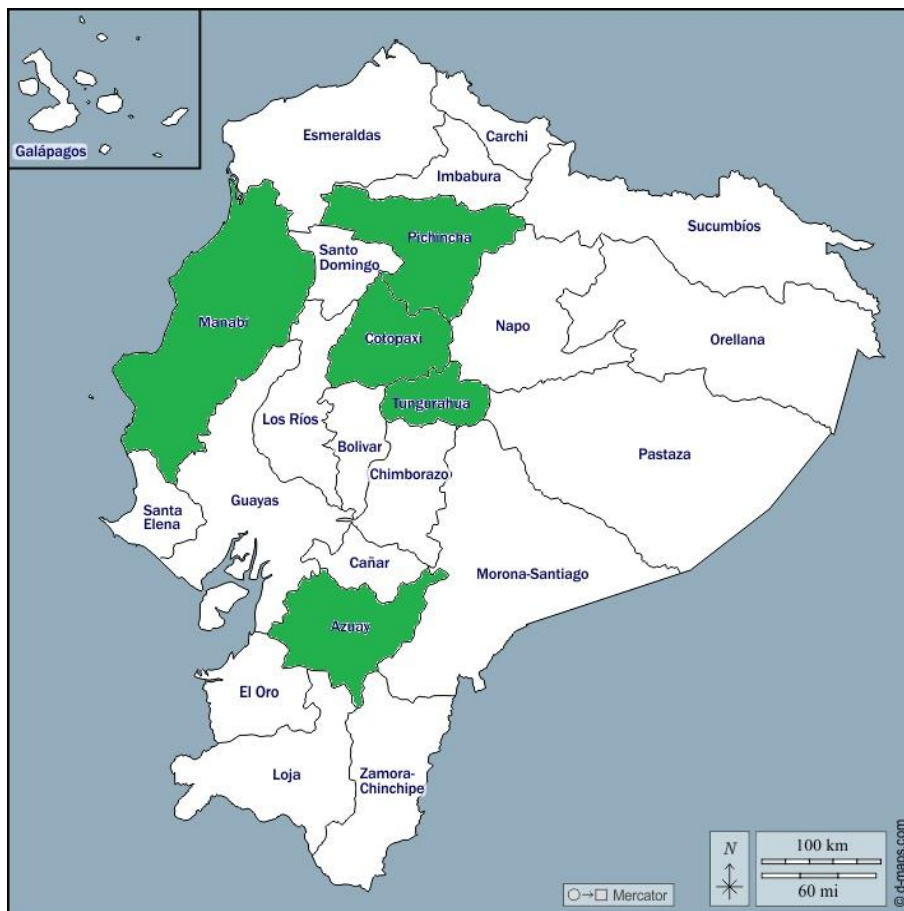
El presente estudio examina la implementación de la IA en la Educación Superior en Ecuador, utilizando datos recopilados durante el semestre comprendido entre octubre de 2024 y marzo de 2025. Ecuador, situado en el noroeste de América del Sur y reconocido por su diversidad geográfica y cultural, presenta dinámicas educativas complejas y variadas que se ven fuertemente influenciadas por su contexto socioeconómico y estructural.

Las instituciones participantes en la investigación se encuentran distribuidas en las provincias de Azuay, Cotopaxi, Manabí, Pichincha y Tungurahua, lo que aporta una muestra representativa de la integración de la IA en diferentes entornos académicos. Si bien los hallazgos obtenidos ofrecen información relevante sobre la adopción y los efectos de la IA en estas regiones, su aplicabilidad a nivel nacional estará condicionada por la variabilidad de factores como la infraestructura tecnológica, las políticas educativas y las condiciones socioeconómicas particulares de cada provincia. Por lo tanto, este estudio se aborda como un “análisis representativo” que, con la debida consideración del contexto, posee el potencial de ser extrapolado a nivel nacional.

A continuación, la Figura 2 presenta un mapa que ilustra la ubicación de las Universidades y Escuelas Politécnicas (UEP) involucradas en la investigación.

Figura 2

Mapa de Ecuador con ubicación de las IES Participantes



Nota. Adaptado de D-Maps (2025).

El estudio se centró en analizar cómo las herramientas basadas en IA influyeron en el desempeño y la experiencia de aprendizaje de los estudiantes, considerando variables como la comprensión de los contenidos, la eficiencia en las tareas y la personalización del aprendizaje. También se investigó la satisfacción de los estudiantes con estas herramientas, evaluando aspectos como la facilidad de uso, accesibilidad, utilidad percibida y motivación.

Además, se midió la confianza de los estudiantes en la precisión y fiabilidad de los resultados generados por la IA y cómo esta confianza afectó su disposición a utilizar estas tecnologías. Se exploraron preocupaciones éticas relacionadas con la

privacidad, el sesgo algorítmico y la equidad en el acceso a la IA, y cómo estas preocupaciones influyeron en la aceptación y uso de la IA en el contexto educativo. La metodología incluyó encuestas y análisis de datos cuantitativos para identificar patrones y tendencias.

Este estudio contribuye a comprender con mayor profundidad el impacto de la IA en la Educación Superior ecuatoriana, a partir de un análisis representativo en diversas regiones del país. Además de generar insumos clave para optimizar su implementación, los hallazgos permiten atender preocupaciones vinculadas con la percepción estudiantil, la confianza en los resultados generados por IA y los dilemas éticos asociados.

Aunque se trata de un estudio de caso focalizado, las perspectivas obtenidas poseen el potencial de extenderse a nivel nacional, siempre que se consideren las diferencias en condiciones tecnológicas, institucionales y socioeconómicas entre provincias. Esta atención al contexto garantiza que la aplicabilidad de los resultados se mantenga relevante y metodológicamente sólida.

Debido a las limitaciones logísticas y de tiempo, se optó por un muestreo “no probabilístico” para la selección de estudiantes y docentes. Este enfoque permitió acceder de manera eficiente a participantes disponibles y relevantes en las IES donde se llevó a cabo el estudio. Sin embargo, al no incluir instituciones de todo el país, los resultados no pueden considerarse representativos de la totalidad de las IES a nivel nacional.

Los tipos de muestreo empleados fueron:

- **Muestreo casual:** Selección al azar de sujetos disponibles en el momento y lugar del estudio (Ortega, 2023).
- **Muestreo intencional:** Selección deliberada basada en el juicio o experiencia del investigador (Parra, 2023).

- **Muestreo por bola de nieve:** Los participantes iniciales recomiendan a otros potencialmente elegibles (Velázquez, 2023).
- **Muestreo por conveniencia:** Selección basada en la facilidad de acceso o disponibilidad (Ortega, 2023).
- **Muestreo por cuotas:** Selección de individuos para mantener proporciones de subgrupos específicos (Velázquez, 2023).

El muestreo no probabilístico fue elegido por:

- **Flexibilidad y rapidez:** Facilitó la recolección de datos en un plazo breve.
- **Accesibilidad:** Permite involucrar a participantes que, por sus características, aportan información relevante al estudio.
- **Exploración inicial:** Adecuado para estudios exploratorios donde se buscan tendencias y generación de hipótesis para futuras investigaciones con muestras probabilísticas.

Se recopilaron datos de un total de 572 participantes, los cuales se distribuyeron de la siguiente manera (ver Tabla 2):

Tabla 1

Descripción de la muestra estudiantes y docentes UEP consideraras en el estudio

	Femenino	Masculino	Prefiero no decirlo	Total
Estudiantes	332	154	3	489
Docentes	36	46	1	83
Total	368	200	4	572

El estudio incluyó la participación de estudiantes y docentes de diversas IES ubicadas en las provincias de Azuay, Cotopaxi, Manabí, Pichincha y Tungurahua, en Ecuador. Los participantes fueron seleccionados de manera que se abarque una variedad de

áreas de estudio, incluyendo Ciencias Sociales, Ingenierías, Ciencias de la Salud, y Artes y Humanidades. Además, se consideraron diferentes niveles académicos, desde estudiantes de pregrado en diversas etapas de sus carreras hasta estudiantes de posgrado. También participaron docentes con una variedad de grados académicos, incluyendo licenciatura, ingeniería, maestría y doctorado.

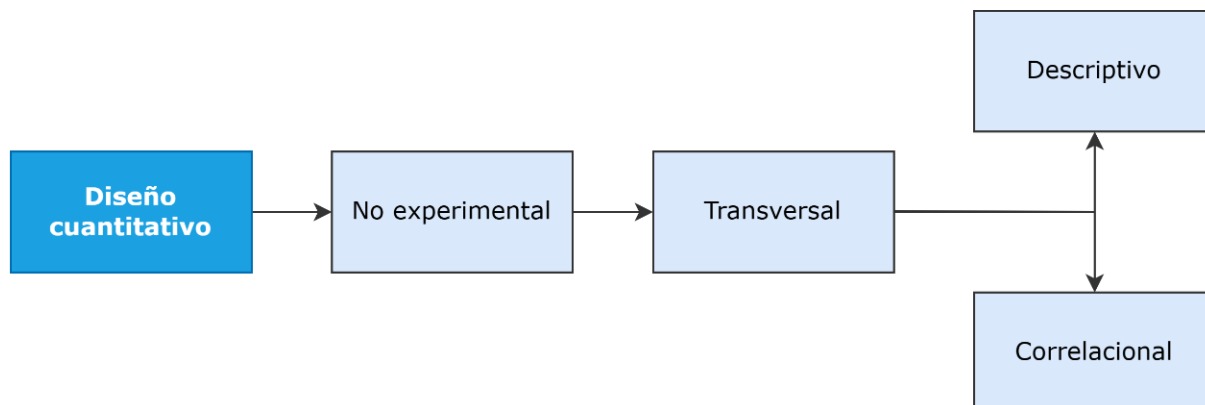
3.2. Enfoque y tipo de investigación

Enfoque

El enfoque de la investigación fue cuantitativo, de corte transversal y de alcance descriptivo observacional. Se analizaron datos de variables recopiladas en un período de tiempo específico sobre una muestra o población definida. Este diseño fue útil para establecer relaciones entre dos o más variables en un momento determinado, buscando objetividad y siguiendo un patrón predecible y estructurado. Las decisiones metodológicas se tomaron antes de la recolección de datos, con el objetivo de aplicar los resultados a una población más amplia. En otras palabras, se describieron, explicaron y predijeron fenómenos, probando hipótesis y formulando teorías. Si se siguió rigurosamente el proceso, los datos generados tendrán validez y confiabilidad, contribuyendo al conocimiento científico. Se utilizó la lógica deductiva, partiendo de la teoría hacia lo particular, con el propósito de identificar leyes universales y capturar la realidad externa (Hernández-Sampieri y Mendoza Torres, 2018). En la Figura 3 se muestra la ruta de la investigación cuantitativa seguida en el Trabajo de Titulación (TDT).

Figura 3

Ruta de la investigación cuantitativa



Nota. Adaptado de Hernández-Sampieri y Mendoza Torres (2018).

Tipo de investigación

Los tipos de investigación utilizados para estimar el proceso de aprendizaje con IA aplicada en la Educación Superior para el estudio de caso fueron los siguientes:

- **Investigación exploratoria:** Sirve para examinar un problema poco estudiado y que vislumbra nuevas perspectivas como es el caso de la IA. Además, antecede a la investigación descriptiva, correlacional y explicativa (Hernández-Sampieri y Mendoza Torres, 2018).
- **Investigación descriptiva:** Se enfoca en analizar la naturaleza de un segmento demográfico, sin intentar entender las razones por las que se originó un fenómeno específico. Es decir, se observó, registró y organizó datos para proporcionar una base sólida de conocimiento que permitiera construir investigaciones más complejas (Rus Arias, 2021; Muguira, 2023).
- **Investigación de campo:** Técnica utilizada para recopilar datos directamente de fuentes primarias. Es decir, se aplicaron encuestas en línea a través de cuestionarios, un recurso que se había convertido en un gran aliado para

investigaciones con bajo presupuesto, ahorrando tiempo y proporcionando inmediatez en los resultados (Stewart, 2024; Software para encuestas Questionpro, 2023).

- **Investigación no experimental:** Técnica en la que las variables se observaron y midieron tal como ocurrieron naturalmente, sin manipulación intencional. Este tipo de investigación pudo o no haber tenido un alcance explicativo y fue la base de varios estudios cuantitativos. Para el estudio, se realizó una encuesta mediante la aplicación de un cuestionario (Hernández-Sampieri y Mendoza Torres, 2018).
- **Investigación correlacional:** Busca entender la conexión o nivel de relación entre dos o más conceptos, variables, categorías o fenómenos dentro de un contexto específico. Además, la técnica correlacional brindó la posibilidad de realizar cierto grado de predicción, que fue el objetivo de la investigación *op.cit.*
- **Investigación explicativa:** Estuvo más dispuesta a comprender los fenómenos o problemas en contextos específicos, proporcionando un sentido de entendimiento del fenómeno al que hacía referencia *op.cit.*

3.3. Definición y operacionalización de variables

Definición de variables

La integración de la IA en la Educación Superior ha transformado los métodos de enseñanza y aprendizaje, influyendo en la forma en que los estudiantes interactúan con los contenidos y en su rendimiento académico. Para evaluar el efecto del uso de la IA, este estudio se centra en analizar la percepción de los estudiantes en tres dimensiones clave:

Satisfacción con el aprendizaje mediado por IA: Esta dimensión se considera un indicador fundamental que refleja la aceptación, motivación y continuidad del aprendizaje de los estudiantes. Se entiende que una percepción positiva de la experiencia con las herramientas de IA promueve la adopción tecnológica y mejora la interacción con los contenidos. Aunque existen otros elementos críticos, diversos

estudios han comprobado que la satisfacción es un predictivo importante de la participación y el compromiso en el proceso educativo.

Nivel de confianza en los resultados proporcionados por la IA: Además de la satisfacción, el estudio busca identificar el grado de confianza que los estudiantes depositan en las herramientas de IA para apoyar sus actividades educativas. Este componente es esencial, ya que la confianza en la tecnología puede influir en la dependencia y la efectividad percibida de estas herramientas en la mejora del aprendizaje.

Apreciación ética sobre el uso de la IA en la educación: La percepción ética constituye otra dimensión relevante, dado que las implicaciones éticas y de protección de datos afectan la aceptación y legitimidad del uso de la IA. Evaluar cómo los estudiantes valoran la transparencia, la rendición de cuentas y el respeto por los derechos humanos en el contexto educativo aporta información valiosa para establecer lineamientos que guíen una implementación responsable de la tecnología. Para la operacionalización de estas dimensiones se adoptan dos variables principales:

- **Variable dependiente:** Se define como el impacto global de la IA en el proceso de aprendizaje, el cual se operacionaliza a través de la satisfacción con el aprendizaje, complementada por indicadores relacionados con el desempeño académico, el compromiso estudiantil, el nivel de confianza en los resultados y la apreciación ética.
- **Variable independiente:** Se refiere a la utilización de herramientas de IA en diversos ámbitos (académico, tecnológico y ético), es decir, el grado de uso y la variedad de aplicaciones de la IA en las actividades educativas.

El cuestionario aplicado recoge datos para medir la satisfacción con el aprendizaje mediante diferentes escalas y preguntas específicas. Se evalúan aspectos clave como la facilidad de uso de la tecnología, la efectividad percibida en el rendimiento académico y la adecuación de la IA a estándares éticos. La Figura 4, con su enfoque multidimensional, ilustra la relación entre la variable dependiente y los factores

influyentes, proporcionando una visión integral que fundamenta el análisis de los objetivos del estudio.

Figura 4

Relación de la variable dependiente con la variable independiente



Nota. Reimpreso de Napkin AI (2024).

Operacionalización de las variables

Tabla 2

Operacionalización de las variables

Variable Dependiente	Dimensión	Indicadores	Escala de Medición	
Satisfacción del aprendizaje	Desempeño	¿Lograron las herramientas IA satisfacer tus expectativas?	Likert (1-5)	
		¿Crees que la IA ha impactado en el desarrollo del pensamiento crítico en el proceso de aprendizaje?	Likert (1-5)	
		¿Consideras que el uso de la IA facilita la comprensión y consecuentemente el rendimiento?	Likert (1-5)	
		¿Le parece conveniente el uso de herramientas IA en apoyo de actividades académicas?	Likert (1-5)	
		¿Qué habilidades consideras mejorar a través de las herramientas de IA?	Nominal (Múltiple respuesta)	
Variable Independiente	Dimensión	Indicadores	Escala de Medición	
Utilización de herramientas IA	Académico	¿Has utilizado herramientas IA?	Nominal (Sí/No)	
		¿Por qué no has utilizado herramientas de IA?	Nominal (Única respuesta)	
		¿La utilización de la IA es sencilla y perceptible?	Likert (1-5)	
		¿La utilización de herramientas IA en el aprendizaje es positiva?	Likert (1-5)	
		¿La IA está mejorando la calidad del trabajo frecuente?	Likert (1-5)	
		¿Cuál es la razón principal por la que utilizas IA en la educación?	Nominal (Múltiple respuesta)	
		¿Qué asistente (<i>Chatbots</i>) IA has utilizado?	Nominal (Múltiple respuesta)	
		Tecnológico	¿Cuánto tiempo a la semana utilizas la IA para tus actividades educativas?	Ordinal (5 categorías)
			¿Has encontrado aspectos confusos o poco intuitivos al usar herramientas IA?	Likert (1-5)
	¿Has encontrado errores en el uso de herramientas IA?		Nominal (Sí/No)	
	¿Cómo calificas tu grado de conocimiento al usar IA?		Likert (1-5)	
	¿Consideras que la IA Puede respetar los principios éticos y los derechos humanos en la educación?		Likert (1-5)	
	¿Consideras que la IA Puede proteger la privacidad y la seguridad de los datos educativos?		Likert (1-5)	
	¿Consideras que la IA Puede garantizar la transparencia y la rendición de cuentas de sus procesos y resultados?		Likert (1-5)	
	¿Consideras que la IA Puede ser crítica y reflexiva sobre sus limitaciones y riesgos?		Likert (1-5)	
	Ética		¿Consideras que la IA Cuenta con lineamientos claros para el uso de herramientas IA?	Likert (1-5)
			¿Citas o referencias el uso de herramientas IA en tus trabajos académicos?	Nominal (Sí/No)
			¿Considera necesario generar y difundir lineamientos claros del uso de herramientas IA?	Nominal (Sí/No)

Nota. El instrumento de medición para la operacionalización de las variables fue un cuestionario en línea.

3.4. Procedimientos

Fase 1: Análisis de la percepción de los estudiantes sobre su nivel de satisfacción con el aprendizaje mediado por Inteligencia Artificial, considerando indicadores como la comprensión de contenidos y el desarrollo de habilidades cognitivas, durante el semestre octubre 2024 – marzo 2025.

Esta fase los resultados obtenidos ofrecieron una primera aproximación a la experiencia del estudiantado frente al uso de la IA como mediadora del proceso educativo.

Para contextualizar adecuadamente dicha percepción, se procedió a caracterizar a los estudiantes que participaron en el estudio, considerando aspectos personales, académicos, institucionales y tecnológicos que podrían influir en la forma en que se relacionan con estas herramientas.

Características de los estudiantes encuestados

Este apartado describe las características de la población estudiada, a partir de un cuestionario estructurado que permitió recopilar información integral sobre diversos aspectos de los estudiantes. En el ámbito personal, se registraron datos básicos, tales como el género (clasificado como masculino, femenino o preferencia por no especificarlo) y los rangos etarios, organizados en grupos (por ejemplo, entre 18 y 25, 26 y 35, 36 y 45, 46 y 60, y más de 60 años), lo que facilita el análisis de la estructura demográfica de la muestra.

En cuanto a las características académicas, se evaluó el nivel de formación, el cual abarca desde los primeros hasta los últimos años de pregrado, complementado con el tipo de Educación Superior alcanzada (técnico/tecnólogo, licenciatura, posgrado, etc.). Asimismo, se registró el área de conocimiento en ejercicio o en formación, considerando categorías específicas como Programas Genéricos y Calificaciones, Educación, Artes y Humanidades, Ciencias Sociales, Periodismo e Información; Administración, Negocios y Legislación; Ciencias Físicas, Naturales, Matemáticas y

Estadísticas; TIC; Ingeniería, Industria y Construcción; Agricultura, Silvicultura, Pesca y Veterinaria; y Salud y Bienestar, entre otras.

Adicionalmente, se recopilaron datos sobre el entorno institucional en el que se encuentran los estudiantes, diferenciando entre instituciones públicas y privadas, y se identificó la ubicación geográfica (provincia) de cada institución, lo que permite contextualizar la distribución regional de la muestra. Finalmente, desde la perspectiva tecnológica, se evaluaron aspectos como el acceso a dispositivos electrónicos y la calidad de la conectividad a internet, elementos esenciales para interactuar con las herramientas de IA en el entorno educativo.

La integración de estas dimensiones ofrece una visión global y contextualizada de las características de los estudiantes encuestados, permitiendo identificar patrones y diferencias relevantes que pueden incidir en la percepción y uso de la IA en el PEA.

Características de los docentes encuestados

El presente estudio definió las características de los docentes encuestados mediante la aplicación de un cuestionario que abarcó diversas dimensiones clave. En primer lugar, en la dimensión personal se recopilaron datos básicos tales como el género (clasificado como masculino, femenino o la opción de preferir no especificarlo) y se establecieron rangos etarios, por ejemplo, entre 26 y 35, 36 y 45, 46 y 60, y mayores de 60 años que reflejan la diversidad en las etapas profesionales de los docentes.

En la dimensión académica, se evaluó el nivel de formación alcanzado por cada docente, abarcando tanto la licenciatura como los diferentes niveles de posgrado (especialización, maestría, doctorado y postdoctorado). Además, se identificó el área de conocimiento en la que ejerce sus funciones, considerando ámbitos tales como Administración, Negocios y Legislación; Ciencias Sociales, Periodismo e Información; Ciencias Físicas, Naturales, Matemáticas y Estadísticas; Educación; Artes y Humanidades; Ingeniería, Industria y Construcción; y Salud y Bienestar, entre otros.

En lo que respecta a la dimensión institucional, se recopiló información sobre el tipo de institución en la que laboran, distinguiendo entre instituciones públicas y privadas,

y se registró la ubicación geográfica (provincia) de cada institución. Estos datos permiten analizar la influencia del entorno regional, la infraestructura y las políticas de innovación educativa en la integración de tecnologías, como la IA, en la práctica docente.

Por último, en la dimensión tecnológica, se evaluaron aspectos relacionados con el acceso a dispositivos electrónicos, la calidad de la conectividad a internet y la familiaridad con el uso de herramientas digitales e IA en el ámbito educativo.

La integración de estas dimensiones ofrece una visión completa y contextualizada del perfil de los docentes encuestados, facilitando el análisis de cómo sus características personales, académicas e institucionales influyen en la implementación y uso de la IA en el PEA.

Importancia de la caracterización de los encuestados

La caracterización de los encuestados es un elemento clave para comprender el contexto en el que se desarrolla la investigación y garantizar una interpretación precisa de los resultados obtenidos. Identificar y analizar sus características permite una evaluación más profunda del impacto de la IA en la Educación Superior, al considerar factores personales, académicos, institucionales y tecnológicos.

En primer lugar, conocer las características de los participantes facilita la contextualización de los hallazgos, ya que las percepciones y actitudes hacia la IA pueden variar según la edad, el género, el nivel de formación y el área de conocimiento en la que se desempeñan. Cada grupo poblacional presenta distintas necesidades y niveles de familiaridad con las herramientas tecnológicas, lo que influye en su grado de aceptación y utilidad percibida.

Asimismo, la caracterización permite identificar tendencias específicas dentro de grupos demográficos particulares. Al analizar si existen patrones diferenciados según la formación académica o el acceso a tecnología, es posible diseñar recomendaciones y estrategias de implementación más efectivas y dirigidas a mejorar la integración de la IA en distintos entornos educativos.

Por último, la caracterización de los encuestados contribuye a asegurar la representatividad de la muestra, garantizando que se incluyan perfiles diversos. Esto fortalece la validez y la posibilidad de generalización de los resultados dentro del contexto de las IES, permitiendo extrapolar los hallazgos a escenarios educativos con características similares.

En conjunto, estas consideraciones refuerzan la importancia de analizar detalladamente los perfiles de los participantes, asegurando que el estudio refleje una visión integral sobre la implementación de la IA en la Educación Superior y sus implicaciones en el proceso de aprendizaje.

Criterios de inclusión

- Estar matriculado como estudiante o ser docente activo en una UEP de Ecuador durante el semestre indicado.
- Tener acceso a herramientas de IA o estar familiarizado con su uso en contextos educativos.
- Aceptar voluntariamente participar en el estudio mediante consentimiento informado.

Procedimiento de consentimiento informado

Antes de iniciar la encuesta, se presentó a los participantes una explicación detallada sobre:

- Objetivos del estudio
- Procedimientos y duración de la encuesta
- Derechos como participantes, incluyendo:
 - Participación voluntaria
 - Posibilidad de abandonar el estudio en cualquier momento sin penalización
 - Garantía de confidencialidad y anonimato de las respuestas

Los participantes otorgaron su consentimiento informado al marcar una casilla de aceptación en el cuestionario en línea, antes de proceder a las preguntas.

Protección de datos y ética

- No se recopilaban datos personales identificables.
- Las respuestas se almacenaron en un servidor seguro (base de datos) y solo el investigador y la tutora tuvieron acceso a dicha información, garantizando la seguridad y confidencialidad de los datos recopilados.
- El estudio cumple con las normativas éticas nacionales e internacionales para investigaciones con seres humanos.

Fase 2: Determinación del nivel de confianza que los estudiantes depositan en los resultados generados por herramientas de Inteligencia Artificial en el contexto de sus actividades académicas, durante el semestre octubre 2024 – marzo 2025

Esta fase se examinó la percepción de fiabilidad, precisión y utilidad de los contenidos generados por estas tecnologías, así como su influencia en las decisiones educativas, hábitos de estudio y criterios de validación del aprendizaje. Este enfoque permitió aproximarse a las condiciones que favorecen la integración funcional y sostenida de la IA en las prácticas pedagógicas universitarias.

En función de los objetivos definidos en esta fase, se procedió a diseñar un enfoque estadístico que permitiera interpretar de forma estructurada los patrones de confianza y sus posibles relaciones con otras variables relevantes. Las técnicas aplicadas en el análisis de datos se describen a continuación.

Métodos

El análisis de los datos recopilados se llevó a cabo mediante una combinación de técnicas estadísticas y modelos matemáticos, permitiendo una interpretación integral de los resultados obtenidos. Se utilizaron los programas Microsoft Excel y RStudio debido a sus capacidades para manejar grandes volúmenes de datos y aplicar

métodos estadísticos avanzados, particularmente en el análisis de datos ordinales (Field, 2018; The R Foundation, 2023).

- **Medidas de tendencia central:** Mediana y moda para datos ordinales, dado que la mediana permite una interpretación más precisa de distribuciones en escala Likert (Field, 2018; Gravetter y Wallnau, 2016).
- **Tablas de frecuencias:** Herramienta clave para resumir la distribución de respuestas en escalas ordinales.
- **Gráficos:** Diagramas de cajas para visualizar la distribución y variabilidad de los datos ordinales.

Pruebas de normalidad

Para evaluar si los datos siguen una distribución normal, se aplicaron las siguientes pruebas:

- **Prueba de Shapiro-Wilk:** Los resultados de esta prueba determinaron si se aplicarían pruebas paramétricas o no paramétricas en análisis posteriores (Shapiro y Wilk, 1965; Ghasemi y Zahediasl, 2012).
- **Prueba de Anderson-Darling:** Esta prueba se utilizó para identificar la mejor distribución que se ajusta a los datos observados y validar la suposición de una distribución normal antes de aplicar pruebas estadísticas paramétricas (SixSigma.us, 2024).

Análisis de correlación

Se utilizó el Coeficiente de Correlación de Spearman para medir la relación entre variables ordinales y no paramétricas, adecuado cuando no se puede asumir normalidad en los datos (Spearman, 1904; Hauke y Kossowski, 2011).

Análisis Factorial Exploratorio (AFE)

El Análisis Factorial Exploratorio permitió identificar estructuras subyacentes en el conjunto de datos y reducir la dimensionalidad (Fabrigar y Wegener, 2012):

- **Prueba de Kaiser-Meyer-Olkin (KMO):** Es una medida de la adecuación del muestreo para el análisis factorial (Kaiser, 1974). Evalúa la proporción de varianza entre variables que podría ser varianza común. La Ecuación 1, muestra su cálculo:

$$KMO_j = \frac{\sum_{i \neq j} r_{ij}^2}{\sum_{i \neq j} r_{ij}^2 + \sum_{i \neq j} u} \quad (1)$$

donde:

R: $[r_{ij}]$ es la matriz de correlación

U: $[u_{ij}]$ es la matriz de covarianza parcial

\sum : es la notación de la suma (“sumar”)

Los valores de KMO oscilan entre 0 y 1, donde valores más altos indican una mayor adecuación para el análisis factorial. La interpretación de valores es: entre 0.8 y 1 son excelentes, 0.6 a 0.8 son aceptables, y menores a 0.6 indican que se necesitan medidas correctivas (Romero, 2020).

- **Prueba de esfericidad de Bartlett:** Resulta significativa cuando $p < 0.001$, confirmando la pertinencia del AFE (Bartlett, 1950). Una prueba significativa indica que las correlaciones entre los ítems no son puramente aleatorias, validando la aplicabilidad del análisis factorial.
- **Método de extracción:** Se utilizó el Análisis de Componentes Principales (ACP) (Jolliffe y Cadima, 2016).
- **Rotación de factores:** Se aplicó la rotación oblicua (*Oblimin*) para facilitar la interpretación de los factores (Costello y Osborne, 2005; IBM Corporation, 2024).
- **Criterios de retención de factores:** Valores propios mayores a 1 (Criterio de Kaiser) y análisis del gráfico de sedimentación (*scree plot*) (Kaiser, 1960; Cattell, 1966).

Análisis Factorial Confirmatorio (AFC)

Se utiliza para probar hipótesis específicas sobre la estructura de los datos, confirmando si los datos se ajustan a un modelo predefinido (Martínez Ávila, 2021).

Análisis de regresión

Se empleó la Regresión Lineal Múltiple (RLM) para modelar la relación entre la variable dependiente y las variables independientes (Field, 2018). La estructura general del modelo se muestra en la Ecuación 2:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad (2)$$

donde:

Y: es la variable dependiente,

X_i: son las variables independientes,

β₀: intercepto

β_i: son los coeficientes,

ε: es el término de error aleatorio.

(Montgomery *et al.*, 2012).

Verificación de supuestos del modelo:

- **Linealidad:** Verificada mediante gráficos de dispersión entre variables independientes y dependiente (Montgomery *et al.*, 2012).
- **Independencia de los errores (autocorrelación):** Prueba de Durbin-Watson para detectar autocorrelación (Durbin y Watson, 1951).
- **Homocedasticidad:** Prueba de Breusch-Pagan para evaluar la igualdad de varianzas (Breusch y Pagan, 1979).
- **Multicolinealidad:** Cálculo del Factor de Inflación de Varianza (VIF), asegurando valores inferiores a 5 (O'Brien, 2007).

Análisis multivariante

El análisis multivariante permite analizar múltiples variables simultáneamente para entender relaciones complejas (Tabachnick y Fidell, 2013). Entre las técnicas comunes del análisis multivariante se encuentra el ACP, utilizado para reducir la dimensionalidad de los datos. La Ecuación 3, muestra su cálculo:

$$Z = XW \quad (3)$$

donde:

Z: es la matriz de componentes principales,

X: es la matriz de datos original,

W: es la matriz de pesos o cargas

(Meneses, 2019).

Análisis de conglomerados (*Cluster Analysis*):

- **Objetivo:** Identificar grupos homogéneos de participantes según sus respuestas (Hair Jr. *et al.*, 2014).
- **Método:** Agrupamiento jerárquico utilizando la distancia euclidiana como medida de similitud (Everitt, 2011). La distancia euclidiana es una medida comúnmente utilizada, tal como se muestra en la Ecuación 4:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4)$$

Procesamiento de datos

Los datos fueron gestionados siguiendo recomendaciones éticas y metodológicas, garantizando confidencialidad y seguridad (Creswell y Creswell, 2022):

- **Limpieza y depuración:** Detección y tratamiento de datos faltantes y atípicos (Hair *et al.*, 2014).

- **Codificación de variables:** Transformación de respuestas categóricas a valores numéricos para análisis (Field, 2018).
- **Análisis estadístico:** Uso de paquetes estadísticos en RStudio, como "psych" y "ggplot2" (Revelle, 2017; Wickham, 2016).

Fase 3: Análisis de la apreciación ética de los estudiantes respecto al uso de la Inteligencia Artificial en el entorno educativo, valorando aspectos como la privacidad, la transparencia y el respeto a los derechos humanos, durante el semestre octubre 2024 – marzo 2025.

En esta fase se permitió reconocer los puntos críticos que emergen cuando la tecnología se inserta en contextos formativos, así como la sensibilidad del estudiantado frente a los riesgos y dilemas éticos que implica su aplicación.

Con base en las dimensiones exploradas durante esta fase, se elaboró un cuestionario que incluyó ítems específicos para indagar sobre estas percepciones. A continuación, se presenta la descripción detallada de las técnicas e instrumentos utilizados para su diseño, validación y aplicación.

Técnicas e instrumentos de investigación

El cuestionario fue diseñado basándose en instrumentos validados en estudios previos relacionados con la IA en educación (Ayuso-del-Puerto y Gutiérrez-Esteban, 2022; Dúo-Terrón *et al.*, 2023; Zamora Varela y Mendoza Encinas, 2023; Multitabajos, 2023; Freepik Company S.L., 2023). Este diseño fue revisado y ajustado para adecuarse al contexto educativo de Ecuador, contando con la supervisión del autor y del tutor del estudio.

Estructura del cuestionario

Datos demográficos:

- Edad
- Género
- Rol (estudiante o docente)

- Área de estudio/enseñanza
- Nivel académico
- Experiencia previa con tecnología
- Acceso a herramientas de IA

Utilización de herramientas de IA:

- Frecuencia de uso
- Tipos de herramientas utilizadas
- Propósito del uso
- Razones para adopción o rechazo

Satisfacción con el aprendizaje:

- Impacto en comprensión de contenidos
- Mejora en rendimiento académico
- Desarrollo de habilidades
- Motivación y compromiso
- Conveniencia del uso de IA

Percepciones éticas:

- Preocupaciones sobre privacidad
- Sesgo algorítmico
- Equidad en el acceso
- Transparencia y rendición de cuentas
- Necesidad de lineamientos claros

Proceso de validación

- **Revisión del autor y tutora del estudio:** El cuestionario se basó en cuestionarios de estudios anteriores y fue revisado por el autor del estudio y su directora, quienes evaluaron su adecuación y pertinencia en relación con los objetivos de la investigación y el contexto educativo ecuatoriano.

- **Adaptación y ajuste:** Se realizaron ajustes en las preguntas del cuestionario para asegurar su claridad, relevancia y alineación con las dimensiones investigadas.

- **Prueba piloto:**
 - Participantes: 20 estudiantes y docentes.
 - Plataforma Utilizada: Formulario de Google.
 - Objetivo: Evaluar claridad, comprensión y tiempo de respuesta (Hernández Sampieri y Mendoza Torres, 2018).
 - Resultados: Alfa de Cronbach de 0.70 que mostró buena consistencia interna (George y Mallery, 2003). Esto significa que los ítems del cuestionario están correlacionados de manera adecuada y miden el mismo constructo subyacente (Oviedo y Campo-Arias, 2005).

- **Ajustes realizados:**
 - Reformulación de preguntas ambiguas.
 - Eliminación de redundancias.
 - Uniformidad en escalas de medición.

- **Administración de la encuesta**
 - Plataforma Utilizada: *Software Qualtrics*, reconocido por su eficacia en investigaciones académicas (Qualtrics, 2023).
 - Distribución: Envío de enlace a través de redes sociales.
 - Período de Recolección: Mes de noviembre 2024.
 - Consentimiento Informado: Incluido al inicio del cuestionario, conforme a pautas éticas (American Psychological Association [APA], 2020).

- **Consideraciones técnicas**
 - **Anonimato:** Configuración para no recopilar información identificable, garantizando la confidencialidad (Gostin *et al.*, 2018).

- **Control de calidad:** Preguntas de atención para asegurar fiabilidad en las respuestas (Meade y Craig, 2012).

La investigación generó una base de datos que fue gestionada, tratada y analizada utilizando programas informáticos como Microsoft Excel y RStudio. En el Anexo B, se presenta el cuestionario final utilizado.

3.5. Consideraciones bioéticas

La investigación se llevó a cabo siguiendo estrictamente principios éticos para proteger los derechos y bienestar de los participantes (Office for Human Research Protections [OHRP], 1979).

Principios éticos aplicados

- **Autonomía:** Se respetó el derecho de los participantes a decidir libremente su participación mediante consentimiento informado (Resnik, 2018).
- **Beneficencia:** Se buscó maximizar beneficios y minimizar riesgos, garantizando que la investigación aporte conocimiento valioso (Beauchamp y Childress, 2019).
- **No maleficencia:** Evitando cualquier daño físico, psicológico o social a los participantes (Beauchamp y Childress, 2019).
- **Justicia:** Trato equitativo y no discriminatorio hacia todos los participantes (OHRP, 1979).

Cumplimiento normativo

- **Declaración de Helsinki:** La investigación se alineó con las pautas éticas para investigaciones médicas y relacionadas con seres humanos (World Medical Association [WMA], 2024).

- **Normativas nacionales:** Cumplimiento de las regulaciones ecuatorianas para investigaciones académicas y protección de datos personales (Asamblea Nacional, 2021).

Protección de datos

- **Confidencialidad:** Datos almacenados de forma segura, acceso restringido al equipo investigador (El Parlamento Europeo y el Consejo de la Unión Europea, 2016).
- **Uso de la información:** Exclusivo para fines académicos y científicos, sin fines comerciales.
- **Eliminación de datos:** Planificada para realizarse cinco años después de finalizado el estudio, siguiendo buenas prácticas (European Commission, 2017).

Derechos de los participantes

- **Retiro del estudio:** Posibilidad de abandonar en cualquier momento sin penalización ni necesidad de justificación (Resnik, 2018).
- **Información de resultados:** Disponibilidad de compartir hallazgos generales con participantes interesados, promoviendo transparencia (Council for International Organizations of Medical Sciences [CIOMS], 2016)
- **Contacto:** Se proporcionaron datos de contacto de los investigadores para resolver dudas o inquietudes.

Notas finales

La inclusión detallada de los procedimientos metodológicos asegura la transparencia y replicabilidad del estudio, aportando rigor científico y confiabilidad a los resultados obtenidos. Al proporcionar una descripción exhaustiva de los métodos, instrumentos y técnicas utilizadas, se cumple con la recomendación de la Guía Metodológica, fortaleciendo el componente analítico del trabajo.

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

En este capítulo se presentan y discuten los hallazgos derivados de la investigación, cuyo objetivo general fue evaluar el impacto del uso de herramientas de IA en el proceso de aprendizaje de los estudiantes de IES en Ecuador, durante el semestre octubre 2024 – marzo 2025.

Fase 1: Análisis de la percepción de los estudiantes sobre su nivel de satisfacción con el aprendizaje mediado por Inteligencia Artificial, considerando indicadores como la comprensión de contenidos y el desarrollo de habilidades cognitivas, durante el semestre octubre 2024 – marzo 2025.

Los resultados se analizaron en función de estos objetivos específicos, lo que permitió obtener una visión integral de cómo la IA está influyendo en el proceso educativo dentro del contexto de las IES que formaron parte del estudio. A continuación, se detallan los hallazgos más relevantes y se discuten sus implicaciones en el marco del contexto educativo actual, sin pretender generalizar a todas las IES, sino ofreciendo un análisis profundo de los casos estudiados.

4.1. Análisis de los resultados

El análisis de resultados de la investigación se ha dividido en dos partes principales para facilitar una comprensión clara y detallada de los hallazgos. La primera parte se enfoca en los resultados relacionados con los estudiantes, mientras que la segunda parte aborda los resultados obtenidos de los docentes. Esta estructuración permite una evaluación específica y comparativa de la percepción del efecto del uso de la IA en el proceso de aprendizaje desde dos perspectivas diferentes.

Resultados estudiantes

De acuerdo con la encuesta aplicada a estudiantes, se describen los resultados generales (género, nivel de formación, edades, área de conocimiento en formación, IES y ubicación provincial) de los 489 estudiantes consultados, quienes colaboraron de manera voluntaria y anónima durante la segunda y tercera semana de noviembre de 2024.

La Tabla 3 presenta características generales de los estudiantes encuestados. La muestra de la investigación estuvo compuesta mayoritariamente por mujeres 67.89%, mientras que los hombres representaron el 31.49% y un 0.61% prefirió no especificar su género. La mayoría de los participantes se encontraba en el primer año de formación 36.40%, seguido por el segundo año 29.86%. En cuanto a la edad, el 82.62% de los encuestados tenía entre 18 y 25 años. Las principales áreas de conocimiento fueron Educación 38.85%, Administración, Negocios y Legislación 29.04%, y Salud y Bienestar 20.25%. El 66.87% de los participantes asistía a instituciones públicas, mientras que el 33.13% asistía a instituciones privadas. Los participantes fueron principalmente de las provincias de Tungurahua 33.54%, seguida por Azuay 24.54% y Manabí 23.52%.

Tabla 3

Características generales de los estudiantes encuestados

Género	Porcentaie	Nivel de formación	Porcentaie
Femenino	67.89%	Primer año (1 - 2 nivel)	36.40%
Masculino	31.49%	Segundo año (3 - 4 nivel)	29.86%
Prefiero no decirlo	0.61%	Tercer año (5 - 6 nivel)	13.91%
		Cuarto año (7 - 8 nivel)	13.50%
		Quinto año (9 - 10 nivel)	2.66%
		Sexto año (11 - 12 nivel)	3.68%
Edad		Área de conocimiento en formación	
Entre 18 y 25	82.62%	Administración. Negocios y Legislación	29.04%
Entre 26 y 35	9.82%	Agricultura. Silvicultura. Pesca y Veterinaria	0.82%
Entre 36 y 45	4.70%	Artes y Humanidades	4.70%
Entre 46 y 60	2.04%	Ciencias Físicas. Ciencias Naturales. Matemáticas y Estadísticas	1.64%
Más de 60	0.82%	Ciencias Sociales. Periodismo e información	0.41%
		Educación	38.85%
		Información y Comunicación (TIC)	2.45%
		Ingeniería. Industria y Construcción	0.82%
		Programas Genéricos y Calificaciones	0.82%
		Salud y Bienestar	20.25%
		Servicios	0.20%
IES		Ubicación provincial de la IES	
Privada	33.13%	Azuay	24.54%
Pública	66.87%	Cotopaxi	8.79%
		Manabí	23.52%
		Pichincha	9.61%
		Tungurahua	33.54%

Uso de herramientas de IA por estudiantes

Los datos obtenidos en la Tabla 4, muestran que el 93.66% de los estudiantes encuestados utiliza herramientas IA, mientras que el 6.34% no las utiliza.

Tabla 4

Frecuencia de uso de herramientas de IA por estudiantes

	Frecuencia	Porcentaje
No	31	6.34%
Sí	458	93.66%
Total	489	100.00%

En relación con el grupo de estudiantes que no utilizan herramientas de IA, la encuesta revela que, dentro de estos 31 casos, un 2.04% indicó que no conoce ninguna herramienta, lo que evidencia una brecha significativa en la difusión de estas tecnologías. Asimismo, un 1.64% manifestó no saber cómo usarlas, mientras que un 0.82% expresó su preferencia por métodos tradicionales. Otros factores, que en conjunto suman un 1.83%, corresponden a la percepción de que las herramientas de IA no son útiles, la falta de tiempo y otras razones adicionales. Estos porcentajes fueron calculados a partir del total de respuestas negativas obtenidas en la encuesta y resaltan la necesidad de implementar programas educativos específicos en IA (Organización para la Cooperación y el Desarrollo Económicos [OCDE], 2021).

Análisis global de las dimensiones datos estudiantes

Para el análisis global de dimensiones utilizando IA, se codificaron las preguntas ordinales (escala Likert) en variables “ x_i ”, facilitando su tratamiento, análisis y visualización. Además, se realizó la equivalencia numérica de la escala Likert, lo que permite asumir que, en escalas de cinco puntos o más, las diferencias entre categorías son aproximadamente iguales. Con esta premisa, se optó por emplear la mediana como medida de tendencia central para resumir los ítems. La Tabla 5 muestra la equivalencia codificada de las preguntas recolectadas de la encuesta y la escala Likert.

Tabla 5

Codificación de las preguntas y equivalencia escala Likert

Pregunta	Codificación
¿La utilización de la IA es sencilla y perceptible?	X ₂
¿La utilización de herramientas IA en el aprendizaje es positiva?	X ₃
¿La IA está mejorando la calidad del trabajo frecuente?	X ₄
¿Cómo calificas tu experiencia al usar IA?	X ₆
Recomendarías el uso de IA para el proceso enseñanza aprendizaje.	X ₇
¿Has encontrado aspectos confusos o poco intuitivos al usar herramientas IA?	X ₁₀
¿Cómo calificas tu grado de conocimiento al usar IA?	X ₁₂
¿Lograron las herramientas IA satisfacer tus expectativas?	X ₁₃
¿Crees que la IA ha impactado en el desarrollo del pensamiento crítico en el proceso de aprendizaje?	X ₁₄
¿Consideras que el uso de la IA facilita la comprensión y consecuentemente el rendimiento?	X ₁₅
¿Le parece conveniente el uso de herramientas IA en apoyo de actividades académicas?	X ₁₆
¿Consideras que la IA puede respetar los principios éticos y los derechos humanos en la educación?	X ₁₈
¿Consideras que la IA puede proteger la privacidad y la seguridad de los datos educativos?	X ₁₉
¿Consideras que la IA puede garantizar la transparencia y la rendición de cuentas de sus procesos y	X ₂₀
¿Consideras que la IA puede ser crítica y reflexiva sobre sus limitaciones y riesgos?	X ₂₁
¿Consideras que la IA cuenta con lineamientos claros para el uso de herramientas IA?	X ₂₂
Escala Likert	Calificaciones
Totalmente en desacuerdo - Muy mala/o	1
desacuerdo - Mala/o	2
Ni de acuerdo ni en desacuerdo - Regular	3
De acuerdo - Buena/o	4
Totalmente de acuerdo - Muy buena/o	5

En la Tabla 6, la dimensión Académica incluye variables como la facilidad de uso de la IA x₂, la percepción positiva de las herramientas IA en el aprendizaje x₃, la mejora de la calidad del trabajo x₄, la calificación de la experiencia x₆ y la recomendación del uso de IA x₇. En esta dimensión se observa un fuerte consenso entre los participantes, ya que tanto la mediana como la moda se ubican en 4, lo que indica que la respuesta más frecuente es una valoración alta. En la dimensión Tecnológica, que abarca aspectos confusos al usar IA x₁₀ y el grado de conocimiento x₁₂, las respuestas se agrupan en torno a una mediana de 3; sin embargo, se evidencia una ligera divergencia en la moda, siendo 4 en x₁₀ y 3 en x₁₂, lo que sugiere que, para x₁₀, aunque el valor central es 3, el número mayor de respuestas se concentra en una valoración superior. En la dimensión Desempeño, que comprende variables relacionadas con la satisfacción con las herramientas IA x₁₃, el impacto en el pensamiento crítico x₁₄, la facilitación de la comprensión x₁₅ y el apoyo en actividades académicas x₁₆, tanto la mediana como la moda se sitúan en 4 para la mayoría de los ítems, enfatizando un consenso sólido entre los participantes. Finalmente, en la dimensión Ética, que evalúa aspectos como el respeto a principios éticos x₁₈, la protección de la privacidad x₁₉, la

capacidad de la IA para garantizar la transparencia x_{20} , su potencial para ser crítica x_{21} y la existencia de lineamientos claros x_{22} , las medianas varían entre 3 y 4. En consonancia, la moda se establece en 3 para la mayoría de las variables, lo que refleja una valoración equilibrada y, en algunos casos, la necesidad de mejorar ciertos aspectos éticos.

Tabla 6

Estadísticos descriptivos de las preguntas de escala Likert estudiantes

Dimensión	Variable	1	2	3	4	5	Mín.	Md	Mo	Máx.
Académica	x_2	21	12	112	212	101	1.00	4.00	4.00	5.00
Académica	x_3	15	25	137	195	86	1.00	4.00	4.00	5.00
Académica	x_4	12	45	123	194	84	1.00	4.00	4.00	5.00
Académica	x_6	4	10	118	200	126	1.00	4.00	4.00	5.00
Académica	x_7	15	22	128	182	111	1.00	4.00	4.00	5.00
Tecnológica	x_{10}	23	47	160	197	31	1.00	3.00	4.00	5.00
Tecnológica	x_{12}	6	14	247	168	23	1.00	3.00	3.00	5.00
Desempeño	x_{13}	7	19	156	221	55	1.00	4.00	4.00	5.00
Desempeño	x_{14}	10	34	115	215	84	1.00	4.00	4.00	5.00
Desempeño	x_{15}	12	26	149	205	66	1.00	4.00	4.00	5.00
Desempeño	x_{16}	8	14	119	234	83	1.00	4.00	4.00	5.00
Ética	x_{18}	22	45	170	157	64	1.00	3.00	3.00	5.00
Ética	x_{19}	19	53	178	162	46	1.00	3.00	3.00	5.00
Ética	x_{20}	22	49	190	157	40	1.00	3.00	3.00	5.00
Ética	x_{21}	19	40	160	178	61	1.00	4.00	4.00	5.00
Ética	x_{22}	17	39	171	179	52	1.00	4.00	4.00	5.00

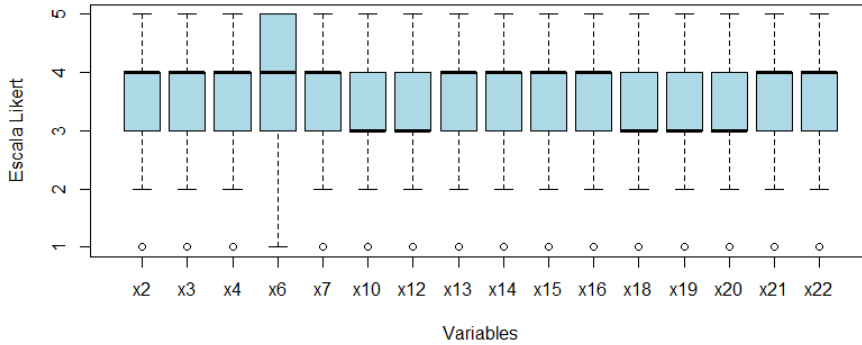
Nota. Totalmente en desacuerdo = 1; En desacuerdo = 2; Ni de acuerdo ni en desacuerdo = 3; De acuerdo = 4; Totalmente de acuerdo = 5; Mínimo = Mín.; Mediana = Md; Moda = Mo; Máximo = Máx.

En resumen, los resultados indican una valoración generalmente positiva sobre el uso de herramientas de IA en la Educación Superior, especialmente en las dimensiones académica y de desempeño. Sin embargo, persisten desafíos en la dimensión ética que deben ser abordados para mejorar la confianza y la aceptación de estas tecnologías en la educación.

El diagrama de cajas de la Figura 5 muestra que, en la dimensión Académica, las variables x_2 a x_7 tienen medianas de 4, lo que indica un fuerte consenso entre los participantes. En contraste, en la dimensión Ética, las variables x_{19} a x_{22} presentan medianas de 3 y 4, reflejando diversidad de opiniones y áreas que requieren atención (Erbas y Maksuti, 2024).

Figura 5

Diagrama de caja de las preguntas de escala Likert estudiantes



Análisis exploratorio de datos estudiantes

En este estudio, se ha llevado a cabo un análisis de correlación de Spearman para evaluar las relaciones entre los ítems obtenidos. Los resultados revelan varias correlaciones significativas que merecen una atención particular. La Figura 6, muestra la correlación de Spearman datos estudiantes.

Figura 6

Correlación de Spearman datos estudiantes

	x ₂	x ₃	x ₄	x ₆	x ₇	x ₁₀	x ₁₂	x ₁₃	x ₁₄	x ₁₅	x ₁₆	x ₁₈	x ₁₉	x ₂₀	x ₂₁	x ₂₂
x ₂	1	0.53***	0.53***	0.51***	0.46***	0.09	0.34***	0.43***	0.41***	0.41***	0.46***	0.26***	0.28***	0.3***	0.34***	0.32***
x ₃	0.53***	1	0.61***	0.52***	0.6***	0.04	0.32***	0.43***	0.38***	0.49***	0.58***	0.33***	0.28***	0.28***	0.26***	0.29***
x ₄	0.53***	0.61***	1	0.49***	0.54***	0.08	0.32***	0.45***	0.42***	0.51***	0.53***	0.37***	0.32***	0.31***	0.33***	0.33***
x ₆	0.51***	0.52***	0.49***	1	0.65***	-0.04	0.48***	0.55***	0.46***	0.45***	0.56***	0.29***	0.28***	0.29***	0.28***	0.36***
x ₇	0.46***	0.6***	0.54***	0.65***	1	0.06	0.38***	0.56***	0.41***	0.54***	0.59***	0.37***	0.33***	0.35***	0.34***	0.33***
x ₁₀	0.09	0.04	0.08	-0.04	0.06	1	0.02	0.09	0.17***	0.08	0.08	0.11*	0.1*	0.09	0.06	0.06
x ₁₂	0.34***	0.32***	0.32***	0.48***	0.38***	0.02	1	0.45***	0.32***	0.27***	0.36***	0.29***	0.23***	0.21***	0.22***	0.29***
x ₁₃	0.43***	0.43***	0.45***	0.55***	0.56***	0.09	0.45***	1	0.47***	0.49***	0.54***	0.32***	0.32***	0.35***	0.34***	0.33***
x ₁₄	0.41***	0.38***	0.42***	0.46***	0.41***	0.17***	0.32***	0.47***	1	0.48***	0.48***	0.26***	0.25***	0.25***	0.33***	0.31***
x ₁₅	0.41***	0.49***	0.51***	0.45***	0.54***	0.08	0.27***	0.49***	0.48***	1	0.63***	0.33***	0.29***	0.34***	0.36***	0.35***
x ₁₆	0.46***	0.58***	0.53***	0.56***	0.59***	0.08	0.36***	0.54***	0.48***	0.63***	1	0.34***	0.37***	0.34***	0.32***	0.35***
x ₁₈	0.26***	0.33***	0.37***	0.29***	0.37***	0.11*	0.29***	0.32***	0.26***	0.33***	0.34***	1	0.58***	0.46***	0.41***	0.46***
x ₁₉	0.28***	0.28***	0.32***	0.28***	0.33***	0.1*	0.23***	0.32***	0.25***	0.29***	0.37***	0.58***	1	0.6***	0.45***	0.54***
x ₂₀	0.3***	0.28***	0.31***	0.29***	0.35***	0.09	0.21***	0.35***	0.25***	0.34***	0.34***	0.46***	0.6***	1	0.57***	0.6***
x ₂₁	0.34***	0.26***	0.33***	0.28***	0.34***	0.06	0.22***	0.34***	0.33***	0.36***	0.32***	0.41***	0.45***	0.57***	1	0.53***
x ₂₂	0.32***	0.29***	0.33***	0.36***	0.33***	0.06	0.29***	0.33***	0.31***	0.35***	0.35***	0.46***	0.54***	0.6***	0.53***	1

Nota. No hay correlación = 0.0 < 0.1; poca correlación = 0.1 < 0.3; correlación media = 0.3 < 0.5; correlación alta = 0.5 < 0.7; correlación muy alta = 0.7 < 1 (Kuckartz *et al.*, 2013, p. 213); Niveles de significancia estadística: ***p < 0.001; **p < 0.01; *p < 0.05.

La correlación de Spearman de los aspectos evaluados en los estudiantes se observa correlaciones altas y estadísticamente significativas. Por ejemplo, entre x_2 (la utilización de la IA es sencilla y perceptible) y x_3 (la utilización de herramientas IA en el aprendizaje es positiva) con un coeficiente de 0.53 y $p < 0.001$, lo que sugiere que cuando los estudiantes perciben la IA como fácil de usar, también tienen una visión positiva de su aplicación en el aprendizaje. Asimismo, la fuerte correlación de 0.65 y $p < 0.001$ entre x_6 (calificación de la experiencia al usar IA) y x_7 (recomendación del uso de IA para el proceso educativo) indica que una experiencia positiva con la IA está estrechamente ligada a la predisposición a recomendar su uso en entornos educativos.

Por el contrario, x_{10} (aspectos confusos o poco intuitivos al usar herramientas IA) muestra correlaciones bajas y no significativas con otras variables, lo que implica que las dificultades en usabilidad no están influyendo significativamente en las percepciones generales positivas o en el rendimiento. Variables como x_{13} (las herramientas IA satisfacen tus expectativas) y x_{15} (el uso de la IA facilita la comprensión y consecuentemente el rendimiento) también presentan correlaciones significativas, resaltando la importancia de la satisfacción y la mejora en el rendimiento académico al utilizar IA.

Además, aunque presenten correlaciones moderadas, las variables relacionadas con aspectos éticos y de derechos humanos, como x_{18} (la IA puede respetar los principios éticos y los derechos humanos en la educación), subrayan la relevancia de estos factores para una implementación responsable de la IA en la educación. En conjunto, este análisis evidencia cómo la percepción de facilidad, satisfacción y consideraciones éticas influye en la aceptación y efectividad del uso de la IA en contextos educativos. Asimismo, las correlaciones bajas y muy bajas indican relaciones débiles entre las variables que, aunque puedan parecer menos relevantes, no deben ser ignoradas, ya que pueden ser determinantes para la satisfacción y motivación de los estudiantes (Holmes *et al.*, 2019).


Fase 2: Determinación del nivel de confianza que los estudiantes depositan en los resultados generados por herramientas de Inteligencia Artificial en el contexto de sus actividades académicas, durante el semestre octubre 2024 – marzo 2025.

Análisis de supuestos previos al AFE de datos estudiantes

El análisis de supuestos es una etapa crucial antes de realizar un AFE para asegurar la validez y fiabilidad de los resultados obtenidos. Es fundamental verificar la normalidad de las variables, ya que, aunque el AFE es relativamente robusto ante desviaciones de normalidad, datos alejados de la distribución normal pueden distorsionar los resultados (Tabachnick y Fidell, 2013). Además, se debe comprobar la linealidad entre las variables observadas y los factores latentes, dado que el AFE asume relaciones lineales (Costello y Osborne, 2005). La ausencia de multicolinealidad es otro supuesto importante, ya que correlaciones excesivamente altas entre variables pueden afectar la interpretación de los factores (Field, 2018). El tamaño de la muestra también debe ser adecuado para obtener estimaciones fiables; se recomienda un tamaño de muestra de al menos 10 veces el número de variables o un mínimo de 300 observaciones (Hair Jr. *et al.*, 2014). Verificar la homogeneidad de varianzas asegura que las varianzas de los errores de predicción sean iguales para todos los valores de las variables independientes (Stevens, 2009). Asimismo, la adecuación muestral y esfericidad, evaluadas mediante el índice KMO y la prueba de esfericidad de Bartlett, son esenciales para determinar la idoneidad de los datos para el AFE (Kaiser, 1974). Llevar a cabo este análisis de supuestos es fundamental para garantizar que los datos cumplen con las premisas necesarias, permitiendo así obtener resultados robustos y significativos en el AFE. En la Figura 7, muestra el comportamiento de los datos obtenidos de los estudiantes evaluando su normalidad y linealidad.

Figura 7

Normalidad y linealidad datos estudiantes



El literal (a) presenta un histograma de resultados con la distribución de valores estandarizados, mostrando una alta frecuencia centrada alrededor de 0, lo que sugiere una tendencia hacia la normalidad. No obstante, se observa una ligera asimetría hacia la derecha, indicando la presencia de valores más altos que podrían influir en el análisis. Esta distribución es fundamental para evaluar la aplicabilidad de pruebas paramétricas en el análisis de datos, asegurando así la validez y fiabilidad de los resultados estadísticos.

Adicionalmente, el literal (b) presenta un gráfico Q-Q que compara los cuantiles de la muestra con los cuantiles teóricos de una distribución normal. La mayoría de los puntos se alinean cerca de la línea de referencia, indicando que los datos siguen una distribución normal en gran medida. Sin embargo, se observan desviaciones en los extremos, sugiriendo la presencia de valores atípicos o colas pesadas. En este sentido, se realizaron cálculos estadísticos como la prueba de normalidad de Anderson-Darling, la cual indicó que ninguna de las variables sigue una distribución normal, ya que los p-valores son menores a $2.2E-16$. Esto sugiere la necesidad de considerar técnicas no paramétricas o transformaciones de datos. Otro cálculo realizado fueron los valores del Factor de Inflación de Varianza (VIF) para todas las variables, que se encuentran por debajo de 10, con un rango de 1.05 a 2.42. Estos resultados indican la ausencia de problemas significativos de multicolinealidad, favoreciendo la estabilidad y confiabilidad de los coeficientes del modelo (Field, 2018).


La adecuación de la muestra $n = 433$ cumple. Sin embargo, la homogeneidad de varianzas no se cumple para la mayoría de las variables, lo que sugiere la necesidad de considerar técnicas robustas que no asuman homogeneidad de varianzas. Con todas las consideraciones mencionadas los datos en general son adecuados para realizar un AFE, posiblemente con la aplicación de técnicas robustas o transformaciones de datos para mejorar la interpretación de los resultados.

La Figura 8 muestra la relación entre los valores ajustados y estandarizados de los datos obtenidos. La dispersión de los puntos indica una ausencia de correlación lineal fuerte entre las variables, ya que los puntos están distribuidos sin un patrón claro. La variabilidad observada alrededor de los ejes sugiere que otros factores podrían estar influyendo en la relación entre las variables. Este análisis es crucial para comprender

el comportamiento de los datos y verificar la precisión de los modelos predictivos utilizados.

Figura 8

Dispersión de las dimensiones datos estudiantes



AFE datos estudiantes

La Tabla 7 presenta los resultados de la prueba de Bartlett y los valores de KMO, sugiriendo que los datos son muy adecuados para un AFE. La mayoría de los valores de Medida de Adecuación Muestral (MSA) son superiores a 0.90, lo que indica una muy buena adecuación de las variables para el análisis. Sin embargo, la variable x_{10} , con un valor de 0.61, podría necesitar una revisión más detallada. En general, los datos son robustos para proceder con el AFE.

Tabla 7

Prueba Bartlett y KMO datos estudiantes

Métrica	Valor	x_i	MSA	x_i	MSA	x_i	MSA	x_i	MSA
X^2	3047.761	x_2	0.94	x_7	0.94	x_{14}	0.95	x_{19}	0.88
p	< 0.001	x_3	0.93	x_{10}	0.61	x_{15}	0.92	x_{20}	0.90
gl	120	x_4	0.94	x_{12}	0.94	x_{16}	0.93	x_{21}	0.92
MSA_g	0.93	x_6	0.92	x_{13}	0.95	x_{18}	0.92	x_{22}	0.93

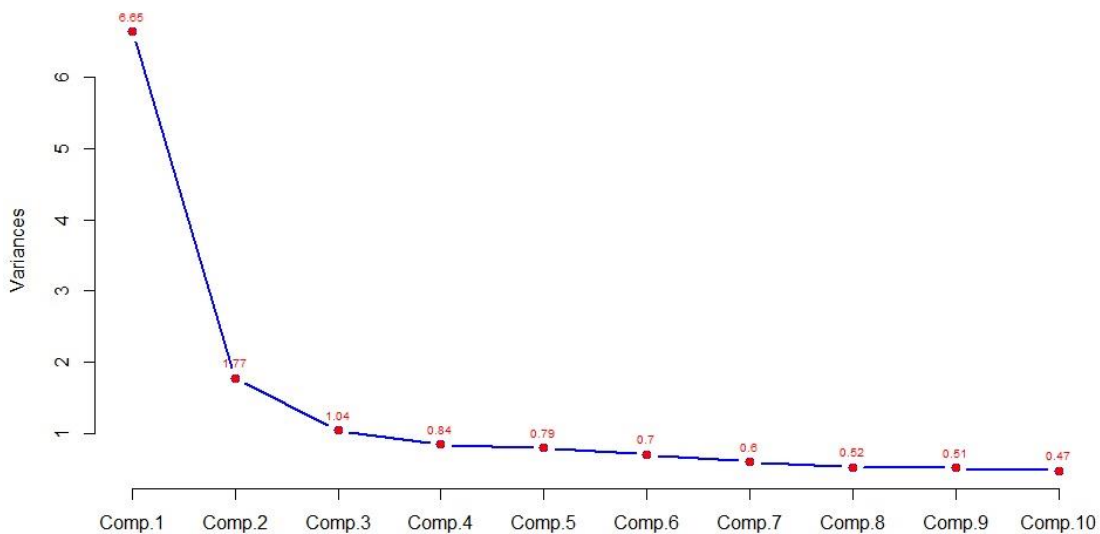
Nota. Chi cuadrado = X^2 ; valor de probabilidad = p; grados de libertad = gl; Variable = x_i ; Medida de Adecuación Muestral = MSA; Medida de Adecuación Muestral general = MSA_g .

ACP datos estudiantes

La Figura 9 muestra que el diagrama de sedimentación del ACP indica que el primer componente principal explica la mayor parte de la varianza en los datos, con un valor de 6.65. A partir del segundo componente, la varianza explicada disminuye drásticamente, estabilizándose por debajo de 1 después del tercer componente. Este patrón sugiere que los primeros componentes son suficientes para capturar la mayor parte de la información relevante del conjunto de datos, lo que es crucial para la reducción de dimensionalidad y la simplificación del modelo sin perder información significativa. En otras palabras, el número de factores a extraer se decide en función del primer cambio significativo en la pendiente del gráfico (Pérez y Medrano, 2010).

Figura 9

Sedimentación del ACP datos estudiantes

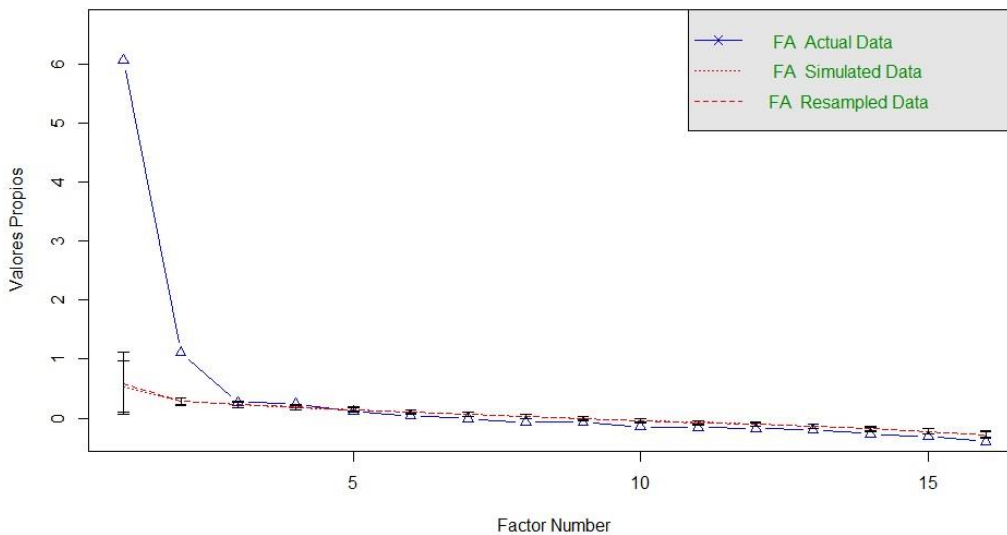


La Figura 10 muestra el análisis paralelo y la determinación del número adecuado de factores a extraer de los datos obtenidos. En el diagrama, los valores propios de los datos reales (representados por cruces azules) disminuyen bruscamente después del primer factor, mientras que los valores propios de los datos simulados (línea verde continua) y re-muestreados (línea roja discontinua) permanecen relativamente constantes. Esto sugiere que solo unos pocos factores son significativos, y el punto donde los valores propios de los datos reales caen por debajo de los valores de los

datos simulados o re-muestreados indica el número óptimo de factores a extraer. Adicionalmente, se realizó un análisis para determinar cuántos valores propios de los factores obtenidos del análisis paralelo son mayores a 0.7 (De la Fuente Fernández, 2011). El resultado indica que hay dos factores significativos con valores propios superiores a 0.7, lo que sugiere que estos factores son los más relevantes para explicar la varianza en los datos obtenidos mediante el uso de IA en la Educación Superior.

Figura 10

Análisis paralelo de factores datos estudiantes



AFC datos estudiantes

La Tabla 8 presenta los resultados del AFC aplicando el criterio de Máxima Verosimilitud (ML) a los datos obtenidos con rotación *oblimin* y dos factores. Las cargas factoriales estandarizadas indican una fuerte asociación de las variables con los factores ML₁ y ML₂. Las comunalidades revelan que una proporción significativa de la varianza es explicada por los factores comunes, mientras que las cargas totales sugieren que ML₁ explica más varianza total que ML₂. En este caso, los dos componentes explican el 47% de la varianza total (Pardo y Ruiz, 2005). Otro aspecto que considerar es la correlación moderada entre los factores 0.58 y los índices de ajuste, como RMSR 0.04, χ^2 significativo, TLI 0.93 y RMSEA 0.07, que sugieren un

buen ajuste del modelo. Además, las altas correlaciones de las puntuaciones de regresión con los factores 0.95 para ML₁ y 0.93 para ML₂ indican que las puntuaciones factoriales son buenas representaciones de los factores. Los resultados del análisis indican que dos factores son suficientes para explicar una parte significativa de la varianza en los datos, con un buen ajuste del modelo y una alta fiabilidad de las puntuaciones factoriales.

Tabla 8

AFC aplicando criterio ML datos estudiantes

Variables	ML₁	ML₂	h₂	u₂	co
x ₂ : La utilización de la IA es sencilla y perceptible	0.6	0.0	0.4	0.6	1.0
x ₃ : La utilización de herramientas IA en el aprendizaje es positiva	0.7	-	0.5	0.4	1.0
x ₄ : La IA está mejorando la calidad del trabajo frecuente	0.6	0.0	0.5	0.4	1.0
x ₆ : Calificación de la experiencia al usar IA	0.7	-	0.5	0.4	1.0
x ₇ : Recomendación del uso de IA para el PEA	0.7	-	0.5	0.4	1.0
x ₁₀ : Aspectos confusos o poco intuitivos al usar herramientas IA	0.0	0.0	0.0	0.9	1.8
x ₁₂ : Grado de conocimiento al usar IA	0.5	0.0	0.2	0.7	1.0
x ₁₃ : Las herramientas IA satisfacen tus expectativas	0.6	0.0	0.5	0.5	1.0
x ₁₄ : La IA ha impactado en el desarrollo del pensamiento crítico en el proceso de aprendizaje	0.5	0.0	0.3	0.6	1.0
x ₁₅ : El uso de la IA facilita la comprensión y consecuentemente el rendimiento	0.6	0.0	0.4	0.5	1.0
x ₁₆ : El uso de herramientas IA en apoyo de actividades académicas	0.7	0.0	0.6	0.4	1.0
x ₁₈ : La IA puede respetar los principios éticos y los derechos humanos en la educación	0.1	0.6	0.4	0.5	1.1
x ₁₉ : La IA puede proteger la privacidad y la seguridad de los datos educativos	-	0.8	0.6	0.3	1.0
x ₂₀ : La IA puede garantizar la transparencia y la rendición de cuentas de sus procesos y	-	0.8	0.6	0.3	1.0
x ₂₁ : La IA puede ser crítica y reflexiva sobre sus limitaciones y riesgos	0.0	0.6	0.4	0.5	1.0
x ₂₂ : La IA cuenta con lineamientos claros para el uso de herramientas IA	0.0	0.7	0.5	0.4	1.0
Saturación de la escala SS	4.7	2.6			
Var. proporcional	0.3	0.1			
Var. Acumulada	0.3	0.4			
Proporción explicada	0.6	0.3			
Proporción acumulada	0.6	1.0			
Con correlaciones factoriales					
ML ₁	1.0	0.5			
ML ₂	0.5	1.0			
Medidas de adecuación de la puntuación factorial					
Correlación de las puntuaciones (de regresión) con los factores	0.9	0.9			
R ² múltiple de las puntuaciones con los factores	0.9	0.8			
Correlación mínima de las posibles puntuaciones factoriales	0.8	0.7			

Nota. Complejidad media de los ítems = 1.1; Prueba de la hipótesis = 2 factores suficientes; gl modelo nulo = 120, función objetivo = 7.16, $\chi^2 = 3047.76$; gl del modelo = 89, la función objetivo = 0.59; RMSR = 0.04; RMSR con gl = 0.04; El n.obs armónico = 433, χ^2 empírico = 146.22, $p < 0.00013$; El n.obs total = 433, χ^2 de verosimilitud = 250.92, $p < 2.4E-17$; Índice de confiabilidad TLI = 0.93; Índice RMSEA = 0.07, intervalos de confianza del 90% = [0.056 0.074]; BIC = -289.37; Ajuste basado en valores fuera de la diagonal = 0.99; Cargas factoriales = ML₁ y ML₂; Comunidades = h₂; Unidades = u₂; comunalidad = com; Grados de libertad = gl; Chi cuadrado = χ^2 ; Cargas Totales = SS loadings; Raíz Cuadrada Media de los Residuos = RMSR; Índice de confiabilidad de factorización de Tucker Lewis = TLI; Índice de Error cuadrático Medio de Aproximación = RMSEA; Criterio de Información Bayesiano = BIC.

Evaluación de la confiabilidad datos estudiantes

La Tabla 9 presenta el análisis de confiabilidad de los datos de ML₁ sobre el uso de la IA en la Educación Superior. Este análisis muestra que el cuestionario tiene una alta consistencia interna, con un alfa de Cronbach de 0.9, lo que indica que los ítems están altamente correlacionados entre sí. El promedio de correlación entre ítems es de 0.47, indicando una correlación moderada. La relación señal/ruido (S/N) es de 8.9, lo que sugiere que la variabilidad en las respuestas se debe principalmente a diferencias reales entre los ítems y no al azar. El error estándar del alfa es bajo, con un valor de 0.0072, lo que indica precisión en la estimación del alfa. La media de las respuestas es 3.7 en una escala de 1 a 5, con una desviación estándar de 0.61, mostrando una variabilidad razonable en las respuestas.

Tabla 9

Análisis de confiabilidad de los datos ML₁ de estudiantes

Métrica	Valor
Alfa de Cronbach (raw_alpha)	0.90
Alfa estandarizado (std.alpha)	0.90
Promedio de correlaciones (average_r)	0.47
Relación señal/ruido (S/N)	8.9
Error estándar de alfa (ase)	0.0072
Media (\bar{x})	3.70
Desviación estándar (s)	0.61
Mediana de correlaciones (md_r)	0.47

La Tabla 10 presenta los límites de confianza al 95% para el alfa de Cronbach de los datos de ML₁ sobre el uso de la IA en la Educación Superior, con intervalos consistentes entre 0.88 y 0.91.

Tabla 10

Límites de confianza al 95% para los datos ML₁ de estudiantes

Método	Inferior	Alfa	Superior
Feldt	0.88	0.90	0.91
Duhachek	0.88	0.90	0.91

La Tabla 11 presenta la confiabilidad de los datos ML₁ sobre el uso de la IA en la Educación Superior si se descarta un elemento. La eliminación de cualquier ítem (variable) no reduce significativamente el alfa de Cronbach, lo que indica que cada ítem contribuye positivamente a la consistencia interna del cuestionario.

Tabla 11

Confiabilidad al descartar un elemento en los datos ML₁ de estudiantes

Variable	raw_alpha	std.alpha	average_r	S/N	alpha se	md.r
X ₂	0.89	0.89	0.48	8.3	0.0077	0.48
X ₃	0.89	0.89	0.46	7.8	0.0082	0.47
X ₄	0.89	0.89	0.47	7.9	0.0081	0.47
X ₆	0.88	0.89	0.46	7.7	0.0082	0.46
X ₇	0.88	0.89	0.46	7.7	0.0083	0.47
X ₁₂	0.90	0.90	0.49	8.8	0.0075	0.49
X ₁₃	0.89	0.89	0.47	7.9	0.0080	0.47
X ₁₄	0.89	0.89	0.48	8.4	0.0075	0.49
X ₁₅	0.89	0.89	0.47	8.1	0.0079	0.47
X ₁₆	0.88	0.88	0.46	7.6	0.0083	0.46

Nota. Alfa de Cronbach sin estandarizar = raw_alpha; Alfa de Cronbach estandarizado = std.alpha; Correlación media entre ítems = average_r; Relación señal/ruido = S/N; Error estándar del Alfa de Cronbach = alpha se; Mediana de las correlaciones entre ítems = md_r.

La Tabla 12 presenta las estadísticas de las variables ML₁ sobre el uso de la IA en la Educación Superior. Las correlaciones ítem-total (r.drop) varían entre 0.50 y 0.73, lo que indica que los ítems están bien correlacionados con el total del cuestionario. Las medias de los ítems varían entre 3.4 y 3.9, y las desviaciones estándar oscilan entre 0.68 y 0.91, indicando una distribución uniforme de las respuestas.

Tabla 12

Estadísticas de las variables ML₁ de estudiantes

Variable	n	r.drop	\bar{x}	s
X ₂	433	0.60	3.8	0.91
X ₃	433	0.69	3.7	0.88
X ₄	433	0.67	3.7	0.91
X ₆	433	0.70	3.9	0.82
X ₇	433	0.70	3.8	0.91
X ₁₂	433	0.50	3.4	0.68
X ₁₃	433	0.67	3.7	0.77
X ₁₄	433	0.57	3.7	0.88
X ₁₅	433	0.64	3.7	0.84
X ₁₆	433	0.73	3.8	0.78

Nota. Tamaño de la muestra = n; Coeficiente de correlación de una variable con el total = r.drop; Media = \bar{x} ; Desviación estándar = s.

La Tabla 13 presenta el análisis de confiabilidad de los datos ML₂ sobre el uso de la inteligencia artificial en la Educación Superior. Este análisis muestra que el cuestionario tiene una alta consistencia interna, con un alfa de Cronbach de 0.85, lo que indica que los ítems (variables) están altamente correlacionados entre sí. El promedio de correlación entre ítems es de 0.53, indicando una correlación moderada. La relación S/N es de 5.6, sugiriendo que la variabilidad en las respuestas se debe principalmente a diferencias reales entre los ítems y no al azar. El error estándar del alfa es bajo, con un valor de 0.012, lo que indica precisión en la estimación del alfa. La media de las respuestas es 3.4 en una escala de 1 a 5, con una desviación estándar de 0.71, mostrando una variabilidad razonable en las respuestas.

Tabla 13

Análisis de confiabilidad de los datos ML₂ de estudiantes

Métrica	Valor
Alfa de Cronbach (raw_alpha)	0.85
Alfa estandarizado (std.alpha)	0.85
Promedio de correlaciones (average_r)	0.53
Relación señal/ruido (S/N)	5.6
Error estándar de alfa (ase)	0.012
Media (mean)	3.40
Desviación estándar (sd)	0.71
Mediana de correlaciones (md_r)	0.54

La Tabla 14 presenta los límites de confianza al 95% para el alfa de Cronbach de los datos de ML₂ sobre el uso de la IA en la Educación Superior, con intervalos consistentes entre 0.82 y 0.87.

Tabla 14

Límites de confianza al 95% para los datos ML₂ de estudiantes

Método	Inferior	Alfa	Superior
Feldt	0.82	0.85	0.87
Duhachek	0.82	0.85	0.87

La Tabla 15 presenta la confiabilidad al descartar un elemento de los datos ML₂ sobre el uso de la inteligencia artificial en la Educación Superior. La eliminación de cualquier ítem no reduce significativamente el alfa de Cronbach, lo que indica que cada ítem contribuye positivamente a la consistencia interna del cuestionario.

Tabla 15

Confiabilidad al descartar un elemento en los datos ML₂ de estudiantes

Variable	raw_alpha	std.alpha	average_r	S/N	alpha se	md.r
X ₁₈	0.83	0.83	0.55	4.9	0.013	0.57
X ₁₉	0.80	0.80	0.51	4.1	0.016	0.50
X ₂₀	0.80	0.80	0.50	4.1	0.016	0.49
X ₂₁	0.83	0.83	0.55	4.9	0.013	0.57
X ₂₂	0.81	0.82	0.53	4.4	0.015	0.53

Nota. Alfa de Cronbach sin estandarizar = raw_alpha; Alfa de Cronbach estandarizado = std.alpha; Correlación media entre ítems = average_r; Relación señal/ruido = S/N; Error estándar del Alfa de Cronbach = alpha se; Mediana de las correlaciones entre ítems = md_r.

La Tabla 16 presenta las estadísticas de las variables ML₂ sobre el uso de la IA en la Educación Superior. Las r.drop varían entre 0.60 y 0.71, lo que indica que los ítems están bien correlacionados con el total del cuestionario. Las medias de los ítems oscilan entre 3.4 y 3.5, y las desviaciones estándar entre 0.86 y 0.97, lo que sugiere una distribución uniforme de las respuestas.

Tabla 16

Estadísticas de las variables ML₂ de estudiantes

Variable	n	r.drop	\bar{x}	s
x18	433	0.60	3.4	0.97
x19	433	0.71	3.4	0.90
x20	433	0.71	3.4	0.87
x21	433	0.60	3.5	0.92
x22	433	0.66	3.5	0.86

Nota. Tamaño de la muestra = n; Coeficiente de correlación de una variable con el total = r.drop; Media = \bar{x} ; Desviación estándar = s.

RLM datos estudiantes

Para el modelo de regresión lineal, inicialmente se consideraron las variables con ML, es decir, aquellas con mayor probabilidad de ocurrir según los datos observados. Adicionalmente, se evaluaron los supuestos del modelo RLM, indicando que en general es factible su aplicación. La prueba de Durbin-Watson mostró un valor DW de 1.8534 y un p-valor de 0.0605, sugiriendo que la independencia de los errores es razonablemente aceptable. La prueba de Breusch-Pagan presentó un valor de BP de 21.279 y un p-valor de 0.0947, lo que indica homocedasticidad. Sin embargo, la prueba de Shapiro-Wilk mostró que los residuos no siguen una distribución normal con p-valor de 4.075E-12, lo cual puede requerir transformaciones de datos o técnicas robustas, aunque este problema es menos crítico con tamaños de muestra grandes. Los valores de VIF estuvieron por debajo de 10, indicando ausencia de problemas significativos de multicolinealidad y sugiriendo la estabilidad y confiabilidad de los coeficientes del modelo. En resumen, aunque la normalidad de los errores es importante, no siempre se exige la validez de su prueba debido a posibles resultados incorrectos. Estudios destacan que estas pruebas son muy sensibles y pueden arrojar resultados incorrectos, especialmente con tamaños de muestra grandes (Yap y Sim, 2011; Montero Granados, 2016). No obstante, los resultados de los demás supuestos fueron favorables para aplicar el modelo de RLM, con posibles ajustes adicionales que pueden mejorar la interpretación de los resultados. En la Tabla 17, muestra las variables iniciales estimadas para el modelo RLM.

Tabla 17

Variables iniciales estimadas para el modelo de RLM

Variable	Relación
X ₂	La utilización de la IA es sencilla y perceptible
X ₃	La utilización de herramientas IA en el aprendizaje es positiva
X ₄	La IA está mejorando la calidad del trabajo frecuente
X ₆	Calificación de la experiencia al usar IA
X ₇	Recomendación del uso de IA para el PEA
X ₁₂	Grado de conocimiento al usar IA
X ₁₃	Las herramientas IA satisfacen tus expectativas
X ₁₄	La IA ha impactado en el desarrollo del pensamiento crítico en el proceso de aprendizaje
X ₁₅	El uso de la IA facilita la comprensión y consecuentemente el rendimiento
X ₁₆	El uso de herramientas IA en apoyo de actividades académicas
X ₁₈	La IA puede respetar los principios éticos y los derechos humanos en la educación
X ₁₉	La IA puede proteger la privacidad y la seguridad de los datos educativos
X ₂₀	La IA puede garantizar la transparencia y la rendición de cuentas de sus procesos y resultados
X ₂₁	La IA puede ser crítica y reflexiva sobre sus limitaciones y riesgos
X ₂₂	La IA cuenta con lineamientos claros para el uso de herramientas IA

La Tabla 18 muestra el modelo completo de RLM basado en las variables estimadas. En este contexto, x_{15} (el uso de la IA facilita la comprensión y, consecuentemente, el rendimiento) se consideró como la variable dependiente (Y) a ser pronosticada. El análisis de RLM realizado indica que x_7 (la recomendación del uso de IA para el proceso de enseñanza-aprendizaje), x_{13} (la satisfacción con las herramientas de IA), x_{14} (el impacto de la IA en el desarrollo del pensamiento crítico) y x_{16} (el uso de herramientas de IA en apoyo de actividades académicas) son factores significativamente relacionados con Y (la facilitación de la comprensión y el rendimiento académico). El modelo sugiere que estos factores explican una parte considerable de la variabilidad en la percepción de que la IA facilita la comprensión y mejora el rendimiento. Además, el modelo es globalmente significativo $p < 0.05$, lo que refuerza la relevancia de estos factores en el contexto educativo.

Tabla 18

Resumen del modelo completo RLM datos estudiantes

Modelo RLM						
lm (formula = Y ~ X ₂ + X ₃ + X ₄ + X ₆ + X ₇ + X ₁₂ + X ₁₃ + X ₁₄ + X ₁₆ + X ₁₈ + X ₁₉ + X ₂₀ + X ₂₁ + X ₂₂ , data = datos1)						
Residuos						
	Mín.	Q₁	Md	Q₃	Máx.	
	-27.190	-0.2549	0.1084	0.3191	17.897	
Coefficientes	Estimación	Error estándar	Valor t	Pr(> t)	Significación	
Y (Intercepto)	0.31233	0.19620	1.592	0.11216		
X ₂	-0.02107	0.04115	-0.512	0.60890		
X ₃	0.03180	0.04840	0.657	0.51150		
X ₄	0.08382	0.04496	1.864	0.06299	.	
X ₆	-0.04400	0.05218	-0.843	0.39952		
X ₇	0.12403	0.04668	2.657	0.00818	**	
X ₁₂	-0.06145	0.05080	-1.210	0.22708		
X ₁₃	0.11436	0.05250	2.178	0.02994	*	
X ₁₄	0.13354	0.04046	3.301	0.00105	**	
X ₁₆	0.42978	0.05415	7.937	1.93e-	***	
X ₁₈	0.02252	0.03982	0.566	0.57190		
X ₁₉	-0.07133	0.04707	-1.515	0.13042		
X ₂₀	0.03469	0.04842	0.716	0.47415		
X ₂₁	0.05572	0.04144	1.345	0.17948		
X ₂₂	0.05709	0.04652	1.227	0.22047		
Signif. Códigos:	0 '***'	0.001 '**'	0.01 '*'	0.05 '.'	0.1 ''	1

Nota. Primer Cuartil = Q₁; Mediana = Md; Tercer Cuartil = Q₃; Mínimo = Mín.; Máximo = Máx.; Grados de libertad = gl; Error estándar residual = 0.6017, gl = 418; R² múltiple = 0.5029; R² ajustado = 0.4862; Estadística F = 30.2, gl₁ = 14, gl₂ = 418; valor p = < 2.2e-16.

Para optimizar el modelo de RLM, se empleó una técnica de selección de variables escalonada basada en el criterio de información de Akaike (AIC). Este método permite ajustar un modelo simplificado a partir del modelo completo inicial, eliminando aquellas variables que no contribuyen significativamente a la explicación de la variable dependiente. El objetivo principal es minimizar el AIC, mejorando así la parsimonia del modelo y asegurando que solo las variables más relevantes sean incluidas en el análisis final. La Tabla 19, muestra los valores resultantes del proceso de selección de variables utilizando el AIC en el modelo RLM. Además, se interpreta el impacto potencial de eliminar cada una de las variables consideradas en el modelo final.

Tabla 19

Modelo final RLM criterio AIC datos estudiantes

Modelo RLM				
AIC=-434.12				
$Y \sim x_4 + x_7 + x_{12} + x_{13} + x_{14} + x_{16} + x_{21}$				
	gl	SS	RSS	AIC
Ninguno			153.12	-434.12
x ₁₂	1	0.7125	153.83	-434.11
x ₁₃	1	16.140	154.73	-431.58
x ₂₁	1	16.330	154.75	-431.53
x ₄	1	16.839	154.80	-431.38
x ₇	1	27.757	155.89	-428.34
x ₁₄	1	40.085	157.12	-424.93
x ₁₆	1	249.794	178.10	-370.68

Nota. Grados de libertad = gl; Suma de Cuadrados = SS; Suma de Cuadrados Residuales = RSS; Criterio de Información de Akaike = AIC.

Antes de realizar el resumen del modelo final RLM se llevó a cabo un análisis exhaustivo del cumplimiento de los supuestos de linealidad, independencia, homocedasticidad, normalidad de los errores y ausencia de multicolinealidad. Aunque una revisión visual de los residuos sugiere patrones que podrían cuestionar la asunción de linealidad, los supuestos de la RLM han sido evaluados con cuidado. La prueba de Durbin-Watson, con un valor DW de 1.8433 y un p-valor de 0.112, confirma la independencia de los residuos, indicando que no hay autocorrelación significativa. La homocedasticidad ha sido validada a través de la prueba de Breusch-Pagan, que arrojó un valor de BP de 13.435 y un p-valor de 0.0622, sugiriendo que la varianza de los residuos es aproximadamente constante. La normalidad de los residuos, aunque cuestionada por un p-valor muy bajo de la prueba de Shapiro-Wilk 5.847E-13, muestra una distribución aproximada a la normalidad en el gráfico

Q-Q, pese a algunas desviaciones en las colas. Además, los valores del VIF, todos por debajo de 10, indican la ausencia de multicolinealidad significativa. Estos resultados sugieren que, aunque la posible no linealidad y la falta de perfecta normalidad de los residuos pueden ser aspectos que considerar, el modelo de RLM sigue siendo útil y adecuado bajo ciertas condiciones, y podría considerarse la aplicación de transformaciones de variables o el uso de modelos no lineales para mejorar el ajuste.

La Tabla 20 muestra el modelo final RLM, considerando tanto el RSS como el AIC resultantes. El modelo RLM indica que el uso de la IA mejora significativamente la comprensión y el rendimiento, con un R^2 ajustado de 0.4888, lo que sugiere que el 49% de la variabilidad en el rendimiento se explica por las variables seleccionadas. Las variables más influyentes incluyen la mejora de la calidad del trabajo frecuente x_4 , $p < 0.05$, la recomendación del uso de IA para el PEA x_7 , $p < 0.01$, la satisfacción con las herramientas de IA x_{13} , $p < 0.05$, el impacto en el desarrollo del pensamiento crítico x_{14} , $p < 0.001$ y el uso de herramientas de IA en apoyo de actividades académicas x_{16} , $p < 0.001$. La variable x_{12} no mostró un impacto significativo $p > 0.05$. Estos resultados sugieren que la integración de la IA en diversas dimensiones del proceso educativo facilita la comprensión y mejora el rendimiento de los estudiantes. En resumen, el modelo RLM obtiene valores de parámetros que minimizan la suma de errores al cuadrado, similar a la regresión simple, optimizando así las predicciones (Crespo Campoverde *et al.*, 2023).

Tabla 20

Resumen del modelo final RLM datos estudiantes

Modelo Final RLM						
lm (formula = Y ~ x ₄ + x ₇ + x ₁₂ + x ₁₃ + x ₁₄ + x ₁₆ + x ₂₁ , data = datos1)						
Residuos						
	Mín.	Q₁	Md	Q₃	Máx.	
Coefficientes	Estimación	Error estándar	Valor t	Pr(> t)	Significación	
Y (Intercepto)	0.31369	0.19003	1.651	0.099541	.	
x ₄	0.08690	0.04020	2.162	0.031179	*	
x ₇	0.11979	0.04316	2.776	0.005752	**	
x ₁₂	-0.06917	0.04918	-1.406	0.160368		
x ₁₃	0.10860	0.05131	2.117	0.034876	*	
x ₁₄	0.13271	0.03979	3.336	0.000926	***	
x ₁₆	0.43151	0.05182	8.327	1.15e-15	***	
x ₂₁	0.07402	0.03477	2.129	0.033828	*	
Signif. Códigos:	0 '***'	0.001 '**'	0.01 '*'	0.05 '.'	0.1 ''	1

Nota. Primer Cuartil = Q₁; Mediana = Md; Tercer Cuartil = Q₃; Mínimo = Mín.; Máximo = Máx.; Grados de libertad = gl; Error estándar residual = 0.6002; gl = 425; R² múltiple = 0.4971; R² ajustado = 0.4888; Estadística F = 60, gl₁ = 7, gl₂ = 425; valor p = < 2.2E-16.

Uso de la IA en la educación: Razones, Herramientas y Frecuencia

La encuesta también recopiló información que respalda el impacto de la IA en el contexto educativo de los estudiantes universitarios, incluyendo razones, herramientas y frecuencia de uso. Como se muestra en la Tabla 21, el análisis de los resultados indica que la mayoría de los usuarios utiliza la IA en la educación principalmente para consultas diarias 19.92% y mejorar la redacción 18.90%. ChatGPT es el asistente de IA más utilizado en clases 41.64%, seguido por Gemini 22.49%. La mayoría de los usuarios emplea la IA menos de 10 horas a la semana 74.45% y más de la mitad 53.93% menciona herramientas de IA en trabajos académicos. Sin embargo, un alto porcentaje 88.43% ha cometido errores en el uso de estas herramientas. Además, el 87.34% de los encuestados considera importante difundir lineamientos claros sobre el uso de herramientas de IA, lo que sugiere una necesidad de mayor orientación y normativas en el ámbito educativo.

Tabla 21

Uso de la IA en la educación: Razones, Herramientas y Frecuencia datos estudiantes

Razón utilización IA en la educación	Porcentaj	Tiempo a la semana de utilización IA educación	Porcentaj
Consultas o inquietudes diarias	19.92%	Menos de 10 horas	74.45%
Mejorar texto y/o redacción (parafraseo)	18.90%	10 a 20 horas	12.01%
Ahorrar tiempo	13.64%	21 a 30 horas	8.08%
Generar contenido como textos, imágenes, presentaciones, videos	12.12%	31 a 40 horas	2.84%
Organizar actividades	8.31%	Más de 40 horas	2.62%
Inspirarse para preparar o realizar tareas	8.22%	Errores en el uso de herramientas IA	
Traducir textos a otros idiomas	7.29%	Sí	88.43%
Automatizar tareas repetitivas	6.44%	No	11.57%
Revisar índice de similitud o plagio	4.41%		
Otra	0.76%		
Asistente IA utilizado en clases		Mejorar habilidades a través de las herramientas de	
ChatGPT	41.64%	Búsqueda de información	18.74%
Gemini (Bard)	22.49%	Selección de información relevante	13.39%
Copilot	11.65%	Capacidad de concreción de ideas	12.91%
Perplexity	8.42%	Modificación de parámetros de búsqueda	8.19%
Claude	7.15%	Aprendizaje de distintos temas	15.04%
Elicit	2.42%	Agilizar procesos para enfocarse en otras	12.13%
Jasper Chat	2.19%	Aprendizaje de otro idioma	6.77%
Otra	4.04%	Otra	12.83%
Referenciar herramientas IA en trabajos académicos		Difundir lineamientos claros del uso de herramientas IA	
Sí	53.93%	Sí	87.34%
No	46.07%	No	12.66%

Resultados docentes

En la encuesta aplicada a docentes se describen los resultados generales y las características relativas al género, nivel de Educación Superior alcanzado, edades, área de conocimiento en ejercicio, tipo de institución y ubicación provincial, a partir de los 83 docentes consultados, quienes colaboraron de manera voluntaria y anónima durante la tercera y cuarta semana de noviembre de 2024. La Tabla 22 presenta características de los docentes encuestados. La mayoría de los docentes encuestados son hombres 55.42% y poseen un nivel educativo de posgrado, siendo la maestría el grado más común 62.65%. La distribución etaria muestra una mayor concentración en el grupo de 46 a 60 años 38.55%. En cuanto a las áreas de conocimiento, Salud y Bienestar es la más representada 30.12%. Además, la mayoría de los docentes participantes son de instituciones públicas 69.88%, con una notable concentración en la provincia de Manabí 36.14%.

Tabla 22

Características de los docentes encuestados

Género	Porcentaje	Nivel de Educación Superior	Porcentaje
Femenino	43.37%	Superior (Técnico/Tecnólogo)	3.61%
Masculino	55.42%	Superior (Licenciatura/Títulos profesionales universitarios o politécnicos y sus equivalentes)	10.84%
Prefiero no decirlo	1.20%	Posgrado (Especialización)	4.82%
		Posgrado (Maestría)	62.65%
		Posgrado (Doctorado/Ph.D.)	15.66%
		Posgrado (Postdoctorado)	2.41%
Edad		Área de conocimiento en formación	
Entre 18 y 25	4.82%	Administración, Negocios y Legislación	8.43%
Entre 26 y 35	16.87%	Agricultura, Silvicultura, Pesca y Veterinaria	2.41%
Entre 36 y 45	34.94%	Ciencias Físicas, Ciencias Naturales, Matemáticas y Estadísticas	20.48%
Entre 46 y 60	38.55%	Ciencias Sociales, Periodismo e información	3.61%
Más de 60	4.82%	Educación	21.69%
		Información y Comunicación (TIC)	6.02%
		Ingeniería, Industria y Construcción	6.02%
		Salud y Bienestar	30.12%
		Servicios	1.20%
IES		Ubicación provincial de la IES	
Privada	30.12%	Azuay	8.43%
Pública	69.88%	Cotopaxi	26.51%
		Manabí	36.14%
		Pichincha	18.07%
		Tungurahua	10.84%

Uso de herramientas de IA por docentes

Los datos obtenidos en la Tabla 23, muestran que el 81.93% de los docentes encuestados utiliza herramientas IA, mientras que el 18.07% no las utiliza.

Tabla 23

Utilización de herramientas IA docentes

	Frecuencia	Porcentaje
No	15	18.07%
Sí	68	81.93%
Total	83	100.00%

En el subgrupo de docentes que no utilizan herramientas de IA, la encuesta reveló diversas razones. Específicamente, un 7.23% menciona que no sabe cómo usarlas; un 4.82% prefiere métodos tradicionales; un 2.41% indica que no tiene tiempo para aprender; y un 1.2% señala que no conoce herramientas de IA. Otros factores que suman en conjunto un 2.41% incluyen la falta de costumbre y otras razones. Estos resultados sugieren que, para aumentar la adopción de herramientas de IA, es necesario ofrecer más educación y capacitación, además de demostrar los beneficios y la eficiencia de estas herramientas en comparación con los métodos tradicionales. IBM destaca que la implementación efectiva de la IA requiere una comprensión profunda de sus capacidades y limitaciones, lo cual se logra a través de una capacitación adecuada (China, 2024).

La resistencia a adoptar nuevas tecnologías en la educación, como la IA, puede estar influenciada por varios factores. Ertmer y Ottenbreit-Leftwich (2010) señalan que uno de los principales obstáculos es la falta de conocimiento y habilidades tecnológicas entre los docentes. La preferencia por métodos tradicionales puede estar arraigada en la comodidad y familiaridad con las prácticas existentes (Cuban, 2001). La falta de tiempo para aprender nuevas herramientas es otro factor significativo, especialmente en contextos educativos con altas cargas de trabajo (Hargreaves, 1995). Para superar estas barreras, es crucial implementar programas de formación continua que enseñen el uso de herramientas de IA y destaquen sus beneficios prácticos y su potencial para mejorar la eficiencia y efectividad en la enseñanza (Hargreaves, 1995; Howard y Mozejko, 2015).

Análisis global de las dimensiones datos docentes

Para el análisis global de dimensiones utilizando IA, se codificaron las preguntas ordinales en variables x_i , lo que facilita su tratamiento y visualización. En la Tabla 24, la dimensión Académica muestra consenso en la facilidad de uso de la IA, su impacto positivo en el aprendizaje y la mejora de la calidad del trabajo. La moda y la mediana en x_2 , x_3 , x_4 , x_6 y x_7 son 4, reflejando una percepción favorable. En la dimensión Tecnológica, la claridad en el uso de IA x_{10} y el conocimiento sobre estas herramientas x_{12} presentan una mediana de 3. La moda en x_{10} es 4, indicando una tendencia a valoraciones más altas, mientras que en x_{12} se mantiene en 3. En la dimensión Desempeño, la satisfacción con las herramientas IA x_{13} , la facilitación de la comprensión x_{15} y el apoyo académico x_{16} tienen medianas y modas de 4, reflejando aceptación. En x_{14} la mediana es 3.5, pero la moda es 4, mostrando inclinación a respuestas positivas. En la dimensión Ética, el respeto a principios éticos y la protección de privacidad en x_{18} y x_{19} tienen una moda de 3, lo mismo que los aspectos de transparencia y rendición de cuentas en x_{20} y x_{21} , señalando diversidad en las opiniones.

Tabla 24

Estadísticos descriptivos de las preguntas de escala Likert docentes


Dimensión	Variable	1	2	3	4	5	Mín.	Md	Mo	Máx.
Académica	x_2	7	4	19	24	14	1.00	4.00	4.00	5.00
Académica	x_3	3	9	13	35	8	1.00	4.00	4.00	5.00
Académica	x_4	2	10	8	38	10	1.00	4.00	4.00	5.00
Académica	x_6	0	3	16	31	18	2.00	4.00	4.00	5.00
Académica	x_7	0	9	13	28	18	2.00	4.00	4.00	5.00
Tecnológica	x_{10}	2	10	27	23	6	1.00	3.00	3.00	5.00
Tecnológica	x_{12}	1	4	34	24	5	1.00	3.00	3.00	5.00
Desempeño	x_{13}	1	4	22	36	5	1.00	4.00	4.00	5.00
Desempeño	x_{14}	3	13	18	25	9	1.00	3.50	4.00	5.00
Desempeño	x_{15}	3	15	14	26	10	1.00	4.00	4.00	5.00
Desempeño	x_{16}	2	5	18	31	12	1.00	4.00	4.00	5.00
Ética	x_{18}	2	6	30	25	5	1.00	3.00	3.00	5.00
Ética	x_{19}	6	15	21	20	6	1.00	3.00	3.00	5.00
Ética	x_{20}	11	17	23	13	4	1.00	3.00	3.00	5.00
Ética	x_{21}	7	11	24	19	7	1.00	3.00	3.00	5.00
Ética	x_{22}	4	10	24	23	7	1.00	3.00	3.00	5.00

Nota. Totalmente en desacuerdo = 1; En desacuerdo = 2; Ni de acuerdo ni en desacuerdo = 3; De acuerdo = 4; Totalmente de acuerdo = 5; Mínimo = Mín.; Mediana = Md; Moda = Mo; Máximo = Máx.

El diagrama de cajas de la Figura 11 muestra que, en la dimensión Académica, las variables x_2 a x_7 presentan un fuerte consenso entre los participantes, con medianas de 4. En la dimensión Tecnológica, las variables x_{10} y x_{12} reflejan una ligera variabilidad en las respuestas, con medianas de 3. En la dimensión Desempeño, las variables x_{13} y x_{16} muestran consenso con medianas de 4, mientras que x_{14} y x_{15} presentan mayor variabilidad. Finalmente, en la dimensión Ética, las variables x_{18} a x_{22} evidencian una mayor diversidad de opiniones, con medianas de 3. Estas observaciones sugieren una marcada coincidencia en las respuestas de la dimensión académica, una variabilidad moderada en la dimensión tecnológica y una diversidad significativa de opiniones en los aspectos éticos.

Figura 11

Diagrama de caja de las preguntas de escala Likert docentes



Análisis exploratorio de datos docentes

Del mismo modo se llevó a cabo un análisis de correlación de Spearman para evaluar las relaciones entre diversas dimensiones obtenidas a través de una encuesta en línea. Los resultados revelan varias correlaciones significativas que merecen una atención particular. La Figura 12, presenta la matriz de correlación de Spearman que muestra la fuerte correlación entre x_6 (Calificación de la experiencia al usar IA) y x_7 (Recomendación del uso de IA para el PEA) 0.67 sugiere que una buena experiencia con la IA fomenta su recomendación en el proceso educativo. La correlación entre x_{12} (Grado de conocimiento al usar IA) y x_6 (Calificación de la experiencia al usar IA) 0.56 indica que un mayor conocimiento de la IA mejora la experiencia de uso. La correlación

entre x_{15} (Facilita la comprensión y el rendimiento) y x_{16} (Apoyo en actividades académicas) 0.53 muestra que la IA es vista como una herramienta útil para mejorar el rendimiento académico. La correlación entre x_{18} (Respeto a principios éticos y derechos humanos) y x_{20} (Transparencia y rendición de cuentas) 0.42 sugiere que los docentes que confían en la ética de la IA también creen en su transparencia.

Figura 12

Correlación de Spearman datos docentes

	x_2	x_3	x_4	x_6	x_7	x_{10}	x_{12}	x_{13}	x_{14}	x_{15}	x_{16}	x_{18}	x_{19}	x_{20}	x_{21}	x_{22}
x_2	1	0.47***	0.49***	0.33**	0.24	-0.09	0.25*	0.33**	0	0.06	0.2	-0.08	-0.1	-0.02	-0.04	-0.08
x_3	0.47***	1	0.51***	0.36**	0.36**	-0.01	0.15	0.28*	0.11	0.21	0.49***	-0.05	-0.08	0.22	0.05	0.03
x_4	0.49***	0.51***	1	0.44***	0.39**	-0.02	0.29*	0.38**	0.25*	0.29*	0.51***	-0.01	0.06	0.29*	0.02	-0.07
x_6	0.33**	0.36**	0.44***	1	0.67***	-0.01	0.56***	0.47***	0.23	0.3*	0.28*	0.24	0.12	0.32**	0.13	0.09
x_7	0.24	0.36**	0.39**	0.67***	1	0.01	0.45***	0.33**	0.21	0.36**	0.31**	0.43***	0.3*	0.32**	0.14	0.08
x_{10}	-0.09	-0.01	-0.02	-0.01	0.01	1	-0.07	-0.11	0.05	-0.17	-0.2	0.14	-0.26*	-0.09	-0.11	-0.09
x_{12}	0.25*	0.15	0.29*	0.56***	0.45***	-0.07	1	0.46***	0.03	0.26*	0.27*	0.39***	0.12	0.34**	0.19	0.16
x_{13}	0.33**	0.28*	0.38**	0.47***	0.33**	-0.11	0.46***	1	0.18	0.4***	0.45***	0.22	0.19	0.26*	0.13	0.06
x_{14}	0	0.11	0.25*	0.23	0.21	0.05	0.03	0.18	1	0.31*	0.27*	0.15	0.13	0.15	0.22	0.21
x_{15}	0.06	0.21	0.29*	0.3*	0.36**	-0.17	0.26*	0.4***	0.31*	1	0.53***	0.38**	0.42***	0.54***	0.25*	0.42***
x_{16}	0.2	0.49***	0.51***	0.28*	0.31**	-0.2	0.27*	0.45***	0.27*	0.53***	1	0.13	0.16	0.35**	0.26*	0.23
x_{18}	-0.08	-0.05	-0.01	0.24	0.43***	0.14	0.39***	0.22	0.15	0.38**	0.13	1	0.3*	0.42***	0.23	0.34**
x_{19}	-0.1	-0.08	0.06	0.12	0.3*	-0.26*	0.12	0.19	0.13	0.42***	0.16	0.3*	1	0.3*	0.42***	0.42***
x_{20}	-0.02	0.22	0.29*	0.32**	0.32**	-0.09	0.34**	0.26*	0.15	0.54***	0.35**	0.42***	0.3*	1	0.34**	0.27*
x_{21}	-0.04	0.05	0.02	0.13	0.14	-0.11	0.19	0.13	0.22	0.25*	0.26*	0.23	0.42***	0.34**	1	0.18
x_{22}	-0.08	0.03	-0.07	0.09	0.08	-0.09	0.16	0.06	0.21	0.42***	0.23	0.34**	0.42***	0.27*	0.18	1

Nota. No hay correlación = $0.0 < 0.1$; poca correlación = $0.1 < 0.3$; correlación media = $0.3 < 0.5$; correlación alta = $0.5 < 0.7$; correlación muy alta = $0.7 < 1$ (Kuckartz et al., 2013, p. 213); Niveles de significancia estadística: ***p < 0.001; **p < 0.01; *p < 0.05.


Análisis de supuestos previos al AFE de datos docentes

La Figura 13 muestra el comportamiento de los datos docentes, evaluando su normalidad y linealidad. El literal (a) presenta un histograma de resultados que muestra la distribución de valores estandarizados, donde la mayor concentración de datos se encuentra en el rango de 0 a 0.5. Esto indica que la mayoría de los valores se agrupan alrededor de la media, sugiriendo una distribución normal. Adicionalmente, el literal (b) presenta un gráfico Q-Q que compara los cuantiles de la muestra con los cuantiles teóricos de una distribución normal. Los puntos en el gráfico representan la relación entre estas dos distribuciones, y la línea de referencia indica dónde se situarían los puntos si las distribuciones fueran idénticas. La proximidad de los puntos a esta línea sugiere que la distribución de la muestra se asemeja a la distribución

teórica, lo cual es útil para evaluar la normalidad de los datos o comparar conjuntos de datos en análisis estadísticos. Se realizaron cálculos estadísticos como la prueba de normalidad de Anderson-Darling, que mostró que ninguna variable sigue una distribución normal $p < 0.05$ en todos los casos. Los gráficos de dispersión verificaron la linealidad entre las variables, mientras que los valores del VIF estuvieron todos por debajo de 10, indicando ausencia de multicolinealidad. El tamaño de la muestra fue adecuado $n = 68$, y la mayoría de las pruebas de Levene indicaron homogeneidad de varianzas $p > 0.05$, excepto para la variable x_7 $p = 0.0145$. En resumen, a pesar de la no normalidad de las variables, los demás supuestos se cumplen razonablemente bien, lo que sugiere que es factible realizar un AFE con estos datos, considerando las limitaciones mencionadas.

Figura 13


Normalidad y linealidad datos docentes



La Figura 14 muestra la relación entre los valores ajustados y estandarizados de los datos obtenidos de los docentes. Los puntos están dispersos a lo largo del gráfico, con una mayor concentración en el centro, lo que sugiere que no hay una clara correlación lineal entre las dos variables. Esta figura es útil para identificar patrones, tendencias y posibles anomalías en los datos de los docentes. La dispersión de los puntos alrededor del centro indica que los valores estandarizados no dependen fuertemente de los valores ajustados, lo cual puede ser relevante para evaluar la independencia de las variables en un análisis estadístico.

Figura 14

Dispersión de las dimensiones datos docentes



AFE datos docentes

La Tabla 25, presenta resultados de la prueba Bartlett y KMO de los datos obtenidos de docentes. En lo concerniente a la prueba de Bartlett produjo un valor de X^2 de 367.68 con un p-valor extremadamente significativo 6.105E-27, lo que sugiere que las correlaciones entre las variables son significativamente diferentes de cero. Esto respalda la idoneidad de las variables para el análisis factorial. El índice KMO general fue de 0.69, considerado aceptable, indicando que los datos son adecuados para el análisis factorial. Sin embargo, algunos ítems presentaron valores KMO bajos, como x_{10} con 0.52 y x_{21} con 0.54, lo que sugiere que podrían no ser tan adecuados para el análisis. En conjunto, estos resultados justifican el seguimiento con el análisis factorial, aunque es deseable revisar los ítems con valores KMO bajos para mejorar la calidad del análisis.

Tabla 25

Prueba Bartlett y KMO datos docentes

Métrica	Valor	x_i	MSA	x_i	MSA	x_i	MSA	x_i	MSA
X^2	367.6805	x_2	0.64	x_7	0.63	x_{14}	0.63	x_{19}	0.55
p	6.10E-15	x_3	0.68	x_{10}	0.52	x_{15}	0.87	x_{20}	0.80
gl	120	x_4	0.71	x_{12}	0.78	x_{16}	0.74	x_{21}	0.54
MSA _g	0.69	x_6	0.73	x_{13}	0.74	x_{18}	0.71	x_{22}	0.57


Nota. Chi cuadrado = X^2 ; valor de probabilidad = p; grados de libertad = gl; Variable = x_i ; Medida de Adecuación Muestral = MSA; Medida de Adecuación Muestral general = MSA_g.

ACP datos docentes

La Figura 15 muestra el diagrama de sedimentación del ACP de los datos obtenidos de los docentes, indicando la varianza explicada por cada componente, con valores que van aproximadamente de 0 a 4.5. Los primeros componentes capturan la mayor parte de la varianza, siendo el primer componente el que explica la mayor varianza, alrededor de 4.28. El gráfico presenta un punto de codo después del tercer o cuarto componente, lo que sugiere que estos primeros componentes son los más significativos. A partir del cuarto componente, la varianza explicada se estabiliza, indicando que los componentes adicionales aportan menos información significativa. Este gráfico es útil para determinar cuántos componentes principales retener para capturar la mayor parte de la variabilidad en los datos.

Figura 15

Sedimentación del ACP datos docentes




La Figura 16 muestra el análisis paralelo y la determinación del número adecuado de factores a extraer de los datos obtenidos de los docentes. El análisis paralelo presenta los valores propios, que varían de 0 a 4. Los datos reales, representados por una línea azul con marcadores de triángulo, muestran una disminución constante de los valores propios a medida que aumenta el número de factores. Los datos simulados, representados por una línea roja discontinua, también disminuyen, pero a un ritmo

diferente. Los datos re-muestreados, representados por una línea púrpura punteada, siguen una tendencia similar a los datos simulados. Este diagrama es útil para determinar el número adecuado de factores a extraer, observando dónde los valores propios de los datos reales comienzan a converger con los de los datos simulados y re-muestreados. Además, se realizó un análisis para determinar cuántos valores propios de los factores obtenidos del análisis paralelo son mayores a 0.7. Los resultados indican que hay tres factores significativos con valores propios superiores a 0.7, lo que sugiere que estos factores son los más relevantes para explicar la varianza en los datos obtenidos de los docentes que usan IA en la Educación Superior.

Figura 16

Análisis paralelo de factores datos docentes



AFC datos docentes

La Tabla 26 muestra el AFC utilizando el método ML con rotación *oblimin* para tres factores mostró que las variables x_6 , x_7 y x_{12} se asociaron fuertemente con el factor ML_1 , mientras que x_2 , x_3 y x_4 se asociaron con ML_2 , y x_{15} , x_{16} , x_{19} y x_{22} con ML_3 . Las comunalidades h_2 indicaron que las variables x_4 , x_6 y x_7 fueron bien explicadas por los factores, mientras que x_{10} y x_{14} no lo fueron. La complejidad media de los ítems fue de 1.5, sugiriendo que la mayoría de las variables se asociaron principalmente con un solo factor. Los tres factores explicaron conjuntamente el 43% de la varianza total, con

ML₃ explicando el 16%, ML₁ el 14% y ML₂ el 13%. Las correlaciones entre los factores fueron moderadas entre ML₁ y ML₃ 0.36, y bajas entre los otros pares. Los índices de ajuste mostraron un buen ajuste del modelo, con un RMSR de 0.06, un RMSEA de 0.03 y un TLI de 0.961. Las puntuaciones factoriales mostraron altas correlaciones con los factores 0.90-0.92 y altos valores de R² múltiple 0.81-0.84, indicando una buena adecuación de las puntuaciones factoriales. En definitiva, el modelo de tres factores es adecuado para los datos, con buenos índices de ajuste y una varianza explicada razonable.

Tabla 26

AFC aplicando criterio ML datos docentes

Variab les	ML₁	ML₂	ML₃	h₂	u₂	com
x ₂ : La utilización de la IA es sencilla y perceptible	0.09	0.53	-	0.34	0.66	1.5
x ₃ : La utilización de herramientas IA en el aprendizaje es positiva	0.13	0.64	-	0.46	0.54	1.1
x ₄ : La IA está mejorando la calidad del trabajo frecuente	0.14	0.73	0.01	0.60	0.40	1.1
x ₆ : Calificación de la experiencia al usar IA	0.82	0.13	-	0.68	0.32	1.1
x ₇ : Recomendación del uso de IA para el PEA	0.77	0.04	0.05	0.64	0.36	1.0
x ₁₀ : Aspectos confusos o poco intuitivos al usar herramientas IA	0.22	-	-	0.10	0.90	2.8
x ₁₂ : Grado de conocimiento al usar IA	0.58	0.00	0.10	0.38	0.62	1.1
x ₁₃ : Las herramientas IA satisfacen tus expectativas	0.24	0.35	0.20	0.31	0.69	2.4
x ₁₄ : La IA ha impactado en el desarrollo del pensamiento crítico en el proceso de aprendizaje	0.06	0.14	0.32	0.15	0.85	1.5
x ₁₅ : El uso de la IA facilita la comprensión y consecuentemente el rendimiento	0.06	0.19	0.72	0.61	0.39	1.2
x ₁₆ : El uso de herramientas IA en apoyo de actividades académicas	-	0.59	0.50	0.61	0.39	2.0
x ₁₈ : La IA puede respetar los principios éticos y los derechos humanos en la educación	0.48	-	0.39	0.55	0.45	2.8
x ₁₉ : La IA puede proteger la privacidad y la seguridad de los datos educativos	0.05	-	0.61	0.40	0.60	1.1
x ₂₀ : La IA puede garantizar la transparencia y la rendición de cuentas de sus procesos y resultados	0.21	0.07	0.53	0.42	0.58	1.4
x ₂₁ : La IA puede ser crítica y reflexiva sobre sus limitaciones y riesgos	0.01	-	0.48	0.24	0.76	1.0
x ₂₂ : La IA cuenta con lineamientos claros para el uso de herramientas IA	-	-	0.62	0.38	0.62	1.2
Saturación de la escala SS	2.20	2.08	2.59			
Var. proporcional	0.14	0.13	0.16			
Var. Acumulada	0.30	0.43	0.16			
Proporción explicada	0.32	0.30	0.38			
Proporción acumulada	0.70	1.00	0.38			
Con correlaciones factoriales						
ML ₁	1.00	0.26	0.36			
ML ₂	0.26	1.00	0.06			
ML ₃	0.36	0.06	1.00			
Medidas de adecuación de la puntuación factorial						
Correlación de las puntuaciones (de regresión) con los factores	0.92	0.90	0.91			
R ² múltiple de las puntuaciones con los factores	0.84	0.81	0.83			
Correlación mínima de las posibles puntuaciones factoriales	0.68	0.62	0.66			

Nota. Complejidad media de los ítems = 1.5; Prueba de hipótesis = 3 factores suficientes; gl modelo nulo = 120, función objetivo = 6,04, $\chi^2 = 367.68$; gl del modelo = 75, la función objetivo = 1.37; RMSR = 0.06; RMSR con gl = 0.07; El n.obs armónico = 68, χ^2 empírico = 52,23, $p < 0.98$; El n.obs total = 68 con χ^2 de verosimilitud = 80,81, $p < 0.3$; Índice de confiabilidad TLI = 0.961; Índice RMSEA = 0.03, intervalos de confianza del 90% = [0 0.079]; BIC = -235.65; Ajuste basado en valores fuera de la diagonal = 0.96; Cargas factoriales = ML₁, ML₂ y ML₃; Comunidades = h₂; Unicidades = u₂; comunalidad = com; Grados de libertad = gl; Chi cuadrado = χ^2 ; Cargas Totales = SS loadings; Raíz Cuadrada Media de los Residuos = RMSR; Índice de confiabilidad de factorización de Tucker Lewis = TLI; Índice de Error cuadrático Medio de Aproximación = RMSEA; Criterio de Información Bayesiano = BIC.

Evaluación de la confiabilidad datos docentes

La Tabla 27 presenta el análisis de confiabilidad de los datos ML_1 obtenidos de los docentes, mostrando un alfa de Cronbach de 0.77, lo que indica una buena consistencia interna de los ítems. Tanto el alfa de Cronbach como el estandarizado presentan el mismo valor de 0.77, reforzando la fiabilidad del instrumento. El promedio de correlaciones entre ítems es 0.46 y la mediana es 0.45, sugiriendo una correlación moderada. La relación S/N de 3.4 indica que la variabilidad de la señal es significativamente mayor que la del ruido, lo cual es favorable. El error estándar de alfa es bajo, 0.045, lo que añade precisión a la estimación de la confiabilidad. La media de las respuestas es 3.6 con una desviación estándar de 0.67, reflejando una dispersión moderada de las puntuaciones. En conjunto, estos resultados sugieren que el instrumento es confiable para evaluar las percepciones de los docentes.

Tabla 27

Análisis de confiabilidad de los datos ML_1 de docentes

Métrica	Valor
Alfa de Cronbach (raw_alpha)	0.77
Alfa estandarizado (std.alpha)	0.77
Promedio de correlaciones (average_r)	0.46
Relación señal/ruido (S/N)	3.4
Error estándar de alfa (ase)	0.045
Media (\bar{x})	3.6
Desviación estándar (s)	0.67
Mediana de correlaciones (md_r)	0.45

La Tabla 28 muestra que los intervalos de confianza del 95% de los datos ML_1 de los docentes para el alfa son consistentes e indican una alta fiabilidad del instrumento. El intervalo de confianza para el método de Feldt varía entre 0.67 y 0.85, mientras que para el método de Duhachek oscila entre 0.68 y 0.86, ambos centrados en un valor alfa de 0.77. Estos resultados sugieren que, con un 95% de confianza, la consistencia interna del instrumento es sólida, lo que refuerza su validez para evaluar las percepciones de los docentes.

Tabla 28

Límites de confianza al 95% para los datos ML₁ de docentes

Método	Inferior	Alfa	Superior
Feldt	0.67	0.77	0.85
Duhachek	0.68	0.77	0.86

La Tabla 29 presenta un análisis de confiabilidad de los datos ML₁ de los docentes, revelando variaciones en la consistencia interna del instrumento al descartar un elemento. Al eliminar el ítem x₆, el alfa de Cronbach disminuye a 0.69, con una correlación promedio de 0.43 y una relación S/N de 2.3. La eliminación del ítem x₇ reduce aún más el alfa a 0.66, con una correlación promedio de 0.39 y una relación S/N de 1.9, indicando una menor fiabilidad. En contraste, al descartar el ítem x₁₂, el alfa aumenta a 0.72, con una correlación promedio de 0.46 y una relación S/N de 2.6, mejorando la consistencia interna. Finalmente, la eliminación del ítem x₁₈ resulta en el alfa más alto de 0.78, con una correlación promedio de 0.54 y una relación S/N de 3.6, sugiriendo que este ítem contribuye significativamente a la fiabilidad del instrumento. Estos resultados indican que la exclusión de ciertos ítems puede mejorar o deteriorar la consistencia interna del instrumento, siendo el ítem x₁₈ el que más favorece la fiabilidad.

Tabla 29

Confiabilidad al descartar un elemento en los datos ML₁ de docentes

Elemento	raw_alpha	std.alpha	average_r	S/N	alpha se	md.r
x ₆	0.69	0.69	0.43	2.3	0.064	0.44
x ₇	0.66	0.66	0.39	1.9	0.073	0.39
x ₁₂	0.72	0.72	0.46	2.6	0.058	0.44
x ₁₈	0.78	0.78	0.54	3.6	0.046	0.50

Nota. Alfa de Cronbach sin estandarizar = raw_alpha; Alfa de Cronbach estandarizado = std.alpha; Correlación media entre ítems = average_r; Relación señal/ruido = S/N; Error estándar del Alfa de Cronbach = alpha se; Mediana de las correlaciones entre ítems = md_r.

La Tabla 30 presenta las estadísticas de las variables ML₁ de los docentes. El ítem x₆ tiene una media de 3.9 y una desviación estándar de 0.83, con una correlación corregida de 0.62, lo que sugiere una buena discriminación del ítem. El ítem x₇ presenta una media de 3.8 y una desviación estándar de 0.98, con una r.drop de 0.68, indicando también una alta capacidad discriminativa. Por otro lado, los ítems x₁₂ y x₁₈ tienen

medias de 3.4, con desviaciones estándar de 0.78 y 0.86, respectivamente. La *r.drop* de estos ítems es 0.56 para x_{12} y 0.45 para x_{18} , lo que sugiere una menor discriminación en comparación con los ítems x_6 y x_7 . En conjunto, estos resultados reflejan que los ítems x_6 y x_7 son más efectivos para diferenciar entre las respuestas de los docentes, mientras que los ítems x_{12} y x_{18} muestran una menor capacidad discriminativa.

Tabla 30

Estadísticas de las variables ML_1 de docentes

Variable	n	r.drop	\bar{x}	s
x_6	68	0.62	3.9	0.83
x_7	68	0.68	3.8	0.98
x_{12}	68	0.56	3.4	0.78
x_{18}	68	0.45	3.4	0.86

Nota. Tamaño de la muestra = n; Coeficiente de correlación de una variable con el total = *r.drop*; Media = \bar{x} ; Desviación estándar = s.

La Tabla 31 analiza la confiabilidad de los datos ML_2 de los docentes. El instrumento utilizado muestra una fiabilidad aceptable, con un alfa de Cronbach de 0.74 y un alfa estandarizada de 0.75, indicando una consistencia interna adecuada. Las correlaciones entre ítems son moderadas, con un promedio de 0.38 y una mediana de 0.43. La relación S/N de 3 y el bajo error estándar de alfa de 0.049 refuerzan la precisión de esta estimación. Las estadísticas descriptivas muestran una media de 3.6 y una desviación estándar de 0.7. En conjunto, estos resultados validan el uso del instrumento para futuras investigaciones.

Tabla 31

Análisis de confiabilidad de los datos ML_2 de docentes

Métrica	Valor
Alfa de Cronbach (raw_alpha)	0.74
Alfa estandarizado (std.alpha)	0.75
Promedio de correlaciones (average_r)	0.38
Relación señal/ruido (S/N)	3
Error estándar de alfa (ase)	0.049
Media (mean)	3.6
Desviación estándar (sd)	0.7
Mediana de correlaciones (md_r)	0.43

La Tabla 32 muestra los intervalos de confianza al 95% de los datos ML₂ de los docentes, calculados mediante los métodos de Feldt y Duhachek, indicando una fiabilidad consistente del instrumento. El alfa de Cronbach se sitúa en 0.74, con intervalos de confianza que varían entre 0.63 y 0.83 para Feldt, y entre 0.65 y 0.84 para Duhachek. Estos resultados sugieren que, con un alto grado de confianza, la fiabilidad del instrumento es adecuada y estable, reforzando su validez para futuras investigaciones.

Tabla 32

Límites de confianza al 95% para los datos ML₂ de docentes

Método	Inferior	Alfa	Superior
Feldt	0.63	0.74	0.83
Duhachek	0.65	0.74	0.84

La Tabla 33 presenta un análisis de confiabilidad de los datos ML₂ de los docentes, revelando que la eliminación de las variables x₂ y x₁₃ mantiene una fiabilidad aceptable del instrumento, con un alfa de Cronbach de 0.74 y una relación S/N de 2.8. En contraste, la eliminación de las variables x₃ y x₄ reduce significativamente la fiabilidad, con alfas de 0.67 y 0.65, respectivamente, y menores relaciones S/N. La variable x₁₆ también muestra una ligera disminución en la fiabilidad, con un alfa de 0.71. Estos resultados sugieren que las variables x₂ y x₁₃ son más consistentes y menos redundantes, mientras que x₃ y x₄ contribuyen menos a la fiabilidad del instrumento, lo que podría indicar la necesidad de revisar o eliminar estos ítems para mejorar la consistencia interna del instrumento.

Tabla 33

Confiabilidad al descartar un elemento en los datos ML₂ de docentes

Variable	raw_alpha	std.alpha	average_r	S/N	alpha se	md.r
x ₂	0.74	0.74	0.41	2.8	0.050	0.44
x ₃	0.67	0.68	0.35	2.1	0.067	0.41
x ₄	0.65	0.65	0.32	1.9	0.070	0.32
x ₁₃	0.73	0.74	0.41	2.8	0.054	0.47
x ₁₆	0.71	0.71	0.38	2.4	0.055	0.42

Nota. Alfa de Cronbach sin estandarizar = raw_alpha; Alfa de Cronbach estandarizado = std.alpha; Correlación media entre ítems = average_r; Relación señal/ruido = S/N; Error estándar del Alfa de Cronbach = alpha se; Mediana de las correlaciones entre ítems = md_r.

La Tabla 34 presenta las estadísticas de las variables ML_2 de los docentes. Las correlaciones r_{drop} varían entre 0.42 y 0.65, sugiriendo que las variables x_3 y x_4 tienen una mayor correlación con el total de la prueba, lo que implica una mayor consistencia interna. Las medias de las variables oscilan entre 3.5 y 3.7, con desviaciones estándar de 0.78 a 1.19, indicando una variabilidad moderada en las respuestas. En particular, la variable x_4 presenta la mayor correlación r_{drop} de 0.65 y una desviación estándar baja de 1.00, lo que sugiere que es un ítem robusto y consistente. Estos resultados destacan la importancia de las variables x_3 y x_4 en la fiabilidad del instrumento y sugieren que estas variables contribuyen significativamente a la consistencia interna del mismo.

Tabla 34

Estadísticas de las variables ML_2 de docentes

Variable	n	r.drop	\bar{x}	sd
X ₂	68	0.43	3.5	1.19
X ₃	68	0.60	3.5	1.01
X ₄	68	0.65	3.6	1.00
X ₁₃	68	0.42	3.6	0.78
X ₁₆	68	0.48	3.7	0.95

Nota. Tamaño de la muestra = n; Coeficiente de correlación de una variable con el total = r_{drop} ; Media = \bar{x} ; Desviación estándar = s.

La Tabla 35 presenta el análisis de confiabilidad de los datos ML_3 de docentes. Se observa una fiabilidad aceptable del instrumento, con un alfa de Cronbach de 0.74 tanto en su forma cruda como estandarizada, lo que indica una consistencia interna adecuada. El promedio de correlaciones entre ítems es de 0.32, y la mediana de 0.29, lo que sugiere correlaciones moderadas entre los ítems. La relación S/N de 2.8 es un indicador positivo de la calidad del instrumento, y el bajo error estándar del alfa 0.049 refuerza la precisión de esta estimación. Las estadísticas descriptivas, con una media de 3.2 y una desviación estándar de 0.72, indican una variabilidad moderada en las respuestas. En conjunto, estos resultados validan la fiabilidad del instrumento y su uso para futuras investigaciones.

Tabla 35

Análisis de confiabilidad de los datos ML₃ de docentes

Métrica	Valor
Alfa de Cronbach (raw_alpha)	0.74
Alfa estandarizado (std.alpha)	0.74
Promedio de correlaciones (average_r)	0.32
Relación señal/ruido (S/N)	2.8
Error estándar de alfa (ase)	0.049
Media (mean)	3.2
Desviación estándar (sd)	0.72
Mediana de correlaciones (median_r)	0.29

La Tabla 36 presenta los límites de confianza al 95% de los datos ML₃ de docentes calculados mediante los métodos de Feldt y Duhachek. Estos métodos muestran una fiabilidad consistente del instrumento. El alfa de Cronbach se sitúa en 0.74, con intervalos de confianza que varían entre 0.63 y 0.82 para Feldt, y entre 0.64 y 0.84 para Duhachek. Estos resultados indican que, con un alto grado de confianza, la fiabilidad del instrumento es adecuada y estable, reforzando su validez para futuras investigaciones.

Tabla 36

Límites de confianza al 95% para los datos ML₃ de docentes

Método	Inferior	Alfa	Superior
Feldt	0.63	0.74	0.82
Duhachek	0.64	0.74	0.84

La Tabla 37 presenta la confiabilidad del instrumento si se descarta un elemento de los datos ML₃ de docentes. Se revela que la eliminación de la variable x₁₄ mejora ligeramente la fiabilidad del instrumento, con un alfa de Cronbach de 0.75 y una relación S/N de 3.0. En contraste, la eliminación de las variables x₁₅ y x₁₉ reduce significativamente la fiabilidad, con alfas de 0.67 y 0.68, respectivamente, y menores relaciones S/N. Las variables x₂₀, x₂₁ y x₂₂ muestran una fiabilidad moderada, con alfas alrededor de 0.70 y relaciones S/N entre 2.3 y 2.4. Estos resultados sugieren que la variable x₁₄ es más consistente y menos redundante, mientras que x₁₅ y x₁₉ contribuyen menos a la fiabilidad del instrumento. Esto podría indicar la necesidad de revisar o eliminar estos ítems para mejorar la consistencia interna del instrumento.

Tabla 37*Confiabilidad al descartar un elemento en los datos ML₃ de docentes*

Variable	raw_alpha	std.alpha	average_r	S/N	alpha se	md.r
X14	0.75	0.75	0.37	3.0	0.048	0.38
X15	0.67	0.67	0.29	2.0	0.063	0.26
X19	0.68	0.68	0.30	2.2	0.060	0.28
X20	0.70	0.70	0.32	2.3	0.058	0.29
X21	0.71	0.71	0.33	2.4	0.056	0.30
X22	0.70	0.70	0.32	2.3	0.057	0.29

Nota. Alfa de Cronbach sin estandarizar = raw_alpha; Alfa de Cronbach estandarizado = std.alpha; Correlación media entre ítems = average_r; Relación señal/ruido = S/N; Error estándar del Alfa de Cronbach = alpha se; Mediana de las correlaciones entre ítems = md_r.

La Tabla 38 presenta las estadísticas de las variables ML₃ de docentes. Las correlaciones r.drop varían entre 0.30 y 0.59, indicando que la variable x₁₅ tiene la mayor correlación con el total de la prueba, lo que sugiere una mayor consistencia interna. Las medias de las variables oscilan entre 2.7 y 3.4, con desviaciones estándar de 1.0 a 1.1, lo que indica una variabilidad moderada en las respuestas. En particular, la variable x₂₀ presenta la media más baja 2.7 y una correlación r.drop moderada 0.49, lo que podría sugerir una menor contribución a la consistencia interna del instrumento. Estos resultados destacan la importancia de la variable x₁₅ en la fiabilidad del instrumento y sugieren que las variables x₁₄ y x₂₀ podrían requerir revisión para mejorar la consistencia interna del mismo.

Tabla 38*Estadísticas de las variables ML₃ de docentes*

Variable	n	r.drop	\bar{x}	s
X14	68	0.30	3.4	1.1
X15	68	0.59	3.4	1.1
X19	68	0.54	3.1	1.1
X20	68	0.49	2.7	1.1
X21	68	0.46	3.1	1.1
X22	68	0.48	3.3	1.0

Nota. Tamaño de la muestra = n; Coeficiente de correlación de una variable con el total = r.drop; Media = \bar{x} ; Desviación estándar = s.

RLM datos docentes

Para el modelo de regresión lineal, se consideran las variables con ML (Tabla 26). Antes de realizar el resumen de la RLM, se llevó a cabo un análisis exhaustivo del cumplimiento de los supuestos de linealidad, independencia, homocedasticidad, normalidad de los errores y ausencia de multicolinealidad. Una revisión visual de los residuos sugiere patrones que podrían cuestionar la asunción de linealidad. La prueba de Durbin-Watson, con un valor DW de 1.9579 y un p-valor de 0.4394, confirma la independencia de los residuos, indicando que no hay autocorrelación significativa. La homocedasticidad ha sido validada a través de la prueba de Breusch-Pagan, que arrojó un valor de BP de 17.537 y un p-valor de 0.2287, sugiriendo que la varianza de los residuos es aproximadamente constante. La normalidad de los residuos fue corroborada con la prueba de Shapiro-Wilk, que mostró un valor W de 0.98084 y un p-valor de 0.3792, respaldada por el gráfico Q-Q que muestra una distribución cercana a la normalidad esperada, a pesar de algunas desviaciones en las colas. Además, los valores del VIF, todos por debajo de 10, indican la ausencia de multicolinealidad significativa. Estos resultados sugieren que, aunque la posible no linealidad y la falta de perfecta normalidad de los residuos pueden ser aspectos que considerar, el modelo de RLM sigue siendo útil y adecuado bajo ciertas condiciones, y podría considerarse la aplicación de transformaciones de variables o el uso de modelos no lineales para mejorar el ajuste.

La Tabla 39 presenta el modelo completo de RLM basado en las variables estimadas, considerando a la variable x_{15} (El uso de la IA facilita la comprensión y, consecuentemente, el rendimiento) como la variable dependiente (Y) a ser pronosticada. Los resultados muestran que los residuos del modelo tienen un rango amplio, desde -215.32 hasta 141.99. Entre las variables independientes, x_{16} (El uso de herramientas IA en apoyo de actividades académicas) y x_{20} (La IA puede garantizar la transparencia y la rendición de cuentas de sus procesos y resultados) mostraron significancia estadística con p-valores de 0.053 y 0.031, respectivamente, sugiriendo una relación significativa con la variable dependiente. Las demás variables no alcanzaron niveles convencionales de significancia. Además, el modelo es globalmente significativo con $p < 0.05$, lo que refuerza la relevancia de estos factores en el contexto educativo.

Tabla 39

Resumen del modelo completo RLM datos docentes

Modelo RLM						
lm (formula = Y ~ X ₂ + X ₃ + X ₄ + X ₆ + X ₇ + X ₁₂ + X ₁₃ + X ₁₄ + X ₁₆ + X ₁₈ + X ₁₉ + X ₂₀ + X ₂₁ + X ₂₂ , data = datos1)						
Residuos						
Min.	Q ₁	Md	Q ₃	Máx.		
-215.323	-0.47251	0.02672	0.54740	141.991		
Coefficientes	Estimación	Error estándar	Valor t	Pr(> t)	Significación	
Y (Intercepto)	-0.688503	0.825089	-0.834	0.4078		
X ₂	0.013622	0.115085	0.118	0.9062		
X ₃	0.007186	0.149908	0.048	0.9619		
X ₄	-0.024767	0.157302	-0.157	0.8755		
X ₆	-0.040535	0.200977	-0.202	0.8409		
X ₇	0.114262	0.184615	0.619	0.5386		
X ₁₂	-0.108607	0.181107	-0.600	0.5513		
X ₁₃	0.182171	0.176199	1.034	0.3059		
X ₁₄	0.082622	0.115725	0.714	0.4784		
X ₁₆	0.320671	0.161843	1.981	0.0527	.	
X ₁₈	0.106417	0.176764	0.602	0.5497		
X ₁₉	0.198483	0.141922	1.399	0.1678		
X ₂₀	0.273755	0.123106	2.224	0.0305	*	
X ₂₁	-0.049577	0.124126	-0.399	0.6912		
X ₂₂	0.151319	0.137268	1.102	0.2753		
Signif. Códigos:	0 '***'	0.001 '**'	0.01 '*'	0.05 '.'	0.1 ''	1

Nota. Primer Cuartil = Q₁; Mediana = Md; Tercer Cuartil = Q₃; Mínimo = Mín.; Máximo = Máx.; Grados de libertad = gl; Error estándar residual = 0,8741, gl = 53; R² múltiple = 0,5168; R² ajustado = 0,3892; Estadística F = 4,05, gl₁ = 14, gl₂ = 53; valor p = 0,0001009.

Para optimizar el modelo de RLM, se empleó la técnica de selección de variables escalonada AIC con el objetivo de minimizar el AIC, mejorando la parsimonia del modelo y asegurando que solo se incluyan las variables más relevantes. La Tabla 40 muestra que el modelo final de RLM incluye las variables x₁₆, x₁₉, x₂₀ y x₂₂, con un AIC de -20.3. La inclusión de estas variables mejora la parsimonia del modelo y destaca su relevancia en el análisis, sugiriendo que son cruciales para el mismo.

Tabla 40

Modelo final RLM criterio AIC datos docentes

Modelo RLM				
AIC=-20.3				
Y ~ X ₁₆ + X ₁₉ + X ₂₀ + X ₂₂				
	gl	Suma de cuadrados	RSS	AIC
Ninguno			43.553	-
X ₁₆	1	14.124	44.965	-
X ₁₉	1	30.687	46.621	-
X ₂₀	1	60.123	49.565	-
X ₂₂	1	78.175	51.370	-

Nota. Grados de libertad = gl; Suma de Cuadrados = SS; Suma de Cuadrados Residuales = RSS; Criterio de Información de Akaike = AIC.

Antes de realizar el resumen del modelo final RLM, se verificaron los supuestos. La prueba de Durbin-Watson, con valor de 2.0853 y p-valor de 0.672, mostró ausencia de autocorrelación significativa, cumpliendo con la independencia. La homocedasticidad se validó mediante la prueba de Breusch-Pagan, con valor de 0.5631 y p-valor de 0.9671, sugiriendo varianza constante en los residuos. La normalidad de los residuos se confirmó mediante la prueba de Shapiro-Wilk, con valor de 0.9702 y p-valor de 0.1031, respaldada por el gráfico Q-Q. Además, los valores del VIF, todos por debajo de 10, indican la ausencia de multicolinealidad significativa. Estos resultados sugieren que el modelo de RLM es adecuado para el análisis de los datos, aunque se podrían considerar transformaciones de variables o modelos no lineales para mejorar el ajuste debido a la posible no linealidad en los residuos.

La Tabla 41 presenta el modelo final RLM. Los resultados muestran que los residuos del modelo tienen un rango de -228.51 a 132.01. Las variables x_{16} (uso de herramientas IA en apoyo de actividades académicas), x_{19} (protección de la privacidad y seguridad de datos educativos) y x_{20} (transparencia y rendición de cuentas) mostraron significancia estadística con p-valores de 0.0013, 0.0391 y 0.0045, respectivamente. La variable x_{22} (lineamientos claros para el uso de IA) no fue significativa. El modelo tiene un R^2 ajustado de 0.4473 y una estadística F de 14.56 con un valor p de $1.79E-08$, indicando una buena capacidad explicativa. Además, el modelo es globalmente significativo con $p < 0.05$, lo que refuerza la relevancia de estos factores en el contexto educativo.

Tabla 41

Resumen del modelo final RLM datos docentes

Modelo Final RLM						
lm (formula =Y ~ X ₁₆ + X ₁₉ + X ₂₀ + X ₂₂ , data = datos1)						
Residuos						
Min.	Q ₁	Md	Q ₃	Máx.		
-228.513	-0.45969	-0.02945	0.54271	132.012		
Coefficientes	Estimación	Error estándar	Valor t	Pr(> t)	Significación	
Y (Intercepto)	-0.07835	0.49226	-0.159	0.87405		
X ₁₆	0.38656	0.11495	3.363	0.00132	**	
X ₁₉	0.22130	0.10504	2.107	0.03912	*	
X ₂₀	0.29796	0.10104	2.949	0.00447	**	
X ₂₂	0.16150	0.11299	1.429	0.15784		
Signif. Códigos:	0 '****'	0.001 '***'	0.01 '**'	0.05 '.'	0.1 ''	1

Nota. Primer Cuartil = Q₁; Mediana = Md; Tercer Cuartil = Q₃; Mínimo = Mín.; Máximo = Máx.; Grados de libertad = gl; Error estándar residual = 0.8315, gl = 63; R² múltiple = 0.4803; R² ajustado = 0.4473; Estadística F = 14.56, gl₁ = 4, gl₂ = 63; valor p = $1.791E-08$.

Uso de la IA en la educación: Razones, Herramientas y Frecuencia

La encuesta también recopiló información sobre el impacto de la IA en el contexto educativo de los docentes universitarios, incluyendo razones, herramientas y frecuencia de uso, como se muestra en la Tabla 42. Las principales razones para utilizar la IA en la educación incluyen mejorar texto y redacción 17.89%, ahorrar tiempo 16.32% y generar contenido 14.21%. La mayoría de los docentes utilizan la IA menos de 10 horas a la semana 60.29% y enfrentan errores en el uso de herramientas de IA en un 86.76% de los casos. Las herramientas más utilizadas son ChatGPT 36.64% y Copilot 19.85%. Además, el 63.24% de los docentes referencia herramientas de IA en trabajos académicos, y el 95.59% considera importante difundir lineamientos claros sobre su uso.

Tabla 42

Uso de la IA en la educación: Razones, Herramientas y Frecuencia datos docentes

Razón utilización IA en la educación	Porcentaje	Tiempo a la semana de utilización IA	Porcentaje
Mejorar texto y/o redacción (parafraseo)	17.89%	Menos de 10 horas	60.29%
Ahorrar tiempo	16.32%	10 a 20 horas	19.12%
Generar contenido como textos, imágenes, presentaciones, videos	14.21%	21 a 30 horas	11.76%
Consultas o inquietudes diarias	11.58%	31 a 40 horas	8.82%
Inspirarse para preparar o realizar	11.58%	Errores en el uso de herramientas IA	
Traducir textos a otros idiomas	10.00%	Sí	86.76%
Automatizar tareas repetitivas	7.37%	No	13.24%
Organizar actividades	5.79%		
Revisar índice de similitud o plagio	4.21%		
Otra	1.05%		
Asistente IA utilizado en clases		Mejorar habilidades a través de las herramientas de IA	
ChatGPT	36.64%	Búsqueda de información	19.49%
Copilot	19.85%	Selección de información relevante	11.79%
Gemini (Bard)	16.79%	Capacidad de concreción de ideas	12.82%
Claude	6.87%	Modificación de parámetros de búsqueda	6.67%
Elicit	6.87%	Aprendizaje de distintos temas	12.82%
Perplexity	6.11%	Agilizar procesos para enfocarse en otras temáticas	13.85%
Jasper Chat	2.29%	Aprendizaje de otro idioma	8.21%
Otra	4.58%	Otra	14.36%
Referenciar herramientas IA en trabajos académicos		Difundir lineamientos claros del uso de herramientas IA	
Sí	63.24%	Sí	95.59%
No	36.76%	No	4.41%

4.2. Discusión

Fase 3: Análisis de la apreciación ética de los estudiantes respecto al uso de la Inteligencia Artificial en el entorno educativo, valorando aspectos como la privacidad, la transparencia y el respeto a los derechos humanos, durante el semestre octubre 2024 – marzo 2025.

Los resultados de este caso de estudio ofrecen una visión profunda sobre la percepción y el uso de la IA por parte de estudiantes y docentes en un grupo seleccionado de IES de Ecuador durante el semestre de octubre 2024 a marzo 2025. Si bien no representan a todas las IES del país, se observa una alta satisfacción estudiantil con el aprendizaje mediado por IA, lo que sugiere una integración exitosa de estas tecnologías en las instituciones evaluadas. Además, el análisis factorial exploratorio reveló que los dos primeros factores explican conjuntamente el 47% de la varianza total de las respuestas, evidenciando la relevancia de la IA en la experiencia educativa actual.

La identificación de variables como x_3 (carga factorial de 0.77 en ML_1) y x_{16} (0.76 en ML_1) sugiere que la IA no solo ha mejorado la calidad del trabajo académico, sino que también ha facilitado una mejor comprensión de los contenidos por parte de los estudiantes. Estos hallazgos están en consonancia con estudios previos que señalan que la IA puede potenciar el aprendizaje al proporcionar recursos personalizados y adaptativos (Hinojo Lucena *et al.*, 2019).

La confianza moderada a alta que los estudiantes tienen en los resultados proporcionados por la IA, evidenciada por las cargas factoriales de x_6 y x_7 (ambas con 0.77 en ML_1), destaca la importancia de la usabilidad y la facilidad de uso de estas herramientas. Esto coincide con el modelo de aceptación tecnológica propuesto por Davis (1989), donde la facilidad de uso percibida influye directamente en la intención de uso y, por ende, en la adopción de nuevas tecnologías.

No obstante, el estudio también revela preocupaciones éticas significativas. Las altas cargas factoriales en variables como x_{19} (0.81 en ML_2) y x_{20} (0.82 en ML_2) indican inquietudes respecto a la transparencia y la protección de la privacidad en el uso de la IA. La variable x_{22} (0.70 en ML_2) resalta la importancia de la rendición de cuentas.

Estas preocupaciones reflejan la necesidad de establecer marcos éticos y legales claros que regulen el uso de la IA en la educación, alineándose con recomendaciones de organismos internacionales (UNESCO, 2021).

El análisis de RLM proporciona una comprensión más detallada de los factores que influyen en la percepción positiva de la IA. El modelo resultó estadísticamente significativo ($F(7, 425) = 60$; $p < 2.2e-16$) con un R^2 ajustado de 0.49, lo que indica que casi la mitad de la variabilidad en la percepción positiva puede explicarse por las variables incluidas en el modelo. Variables como x_4 (calidad de la experiencia al usar IA) y x_7 (facilidad de uso de la IA) presentan asociaciones positivas y significativas, lo que refuerza la importancia de proporcionar experiencias de usuario de alta calidad para fomentar una percepción favorable.

Destaca particularmente la variable x_{16} (recomendación del uso de la IA), que mostró la asociación más fuerte (estimación = 0.4315; $***p < 1.15E-15$). Este hallazgo sugiere que los estudiantes no solo están satisfechos con la IA, sino que también están dispuestos a recomendar su uso, lo cual puede tener un efecto multiplicador en la adopción de estas tecnologías. Por otra parte, aunque la variable x_{12} (grado de conocimiento al usar IA) no resultó significativa, esto indica que la percepción positiva de la IA no depende necesariamente del nivel de conocimiento previo, sino más bien de la experiencia directa y los beneficios percibidos.

La perspectiva de los docentes complementa y refuerza los hallazgos obtenidos de los estudiantes. El AFE mostró que los tres primeros factores principales explican conjuntamente el 70% de la varianza total, y variables como x_6 (carga factorial de 0.82 en ML_1) y x_4 (0.73 en ML_2) señalan que los docentes también valoran positivamente la calidad de la experiencia y la mejora en la calidad del trabajo proporcionadas por la IA. Las preocupaciones éticas reflejadas en variables como x_{19} y x_{20} demuestran que tanto estudiantes como docentes comparten inquietudes sobre la transparencia y la privacidad, lo que evidencia una necesidad institucional de abordar estos temas.

El modelo final de RLM para los docentes fue igualmente significativo ($F(4, 63) = 14.56$; $p = 1.79E-08$) con un R^2 ajustado de 0.4473. Las variables x_{16} (uso de herramientas de IA), x_{19} (protección de la privacidad) y x_{20} (transparencia) resultaron

ser factores determinantes en la percepción positiva de la IA por parte de los docentes. Esto indica que, al igual que los estudiantes, los docentes valoran tanto los beneficios funcionales de la IA como el cumplimiento de consideraciones éticas.

Estos resultados tienen varias implicaciones prácticas. Primero, la alta satisfacción y confianza en la IA sugieren que su integración en el currículo y las prácticas pedagógicas podría amplificarse. Sin embargo, las preocupaciones éticas identificadas señalan que, para una adopción sostenible y responsable, es crucial implementar políticas claras que aborden la privacidad, la transparencia y la rendición de cuentas. Las instituciones educativas deben considerar la elaboración de reglamentos éticos y ofrecer capacitaciones tanto a docentes como a estudiantes sobre el uso responsable de la IA.

Además, el hecho de que la facilidad de uso influya significativamente en la percepción positiva resalta la importancia de diseñar herramientas de IA con interfaces intuitivas y experiencias de usuario optimizadas. Los desarrolladores y proveedores de tecnología deben colaborar estrechamente con las instituciones educativas para adaptar las herramientas a las necesidades específicas del contexto educativo ecuatoriano.

Es importante reconocer ciertas limitaciones en este estudio. La muestra está circunscrita a IES de Ecuador en un período específico, lo que puede limitar la generalización de los resultados a otros contextos geográficos o temporales. Futuros estudios podrían ampliar la muestra e incluir variables adicionales, como el rendimiento académico cuantitativo o indicadores socioeconómicos, para enriquecer el análisis.

En suma, este estudio aporta evidencia significativa sobre la percepción y el uso de la IA en un grupo específico de IES analizadas en Ecuador. Si bien los resultados reflejan altos niveles de satisfacción y confianza en estas tecnologías dentro del caso de estudio, también se identifican desafíos éticos que deben ser abordados para garantizar una implementación responsable. Las instituciones participantes tienen la oportunidad de liderar este proceso, promoviendo un equilibrio entre la innovación tecnológica y la responsabilidad ética, con el fin de maximizar el impacto positivo de la IA en la formación de los futuros profesionales.

CONCLUSIONES Y RECOMENDACIONES

Conclusiones

Este estudio exploró a fondo la percepción y el uso de la IA por parte de los estudiantes en un grupo específico de IES analizadas en Ecuador durante el semestre de octubre 2024 a marzo 2025. Los hallazgos proporcionan perspectivas clave sobre la satisfacción con el aprendizaje mediado por IA, el nivel de confianza en los resultados generados por estas herramientas y la apreciación ética que los estudiantes tienen respecto a su integración en la Educación Superior dentro del contexto de las instituciones evaluadas.

- En primer lugar, los estudiantes expresaron una alta satisfacción con el aprendizaje mediado por IA. El AFE indicó que los dos primeros factores principales explican conjuntamente el 47% de la varianza total en las respuestas. Variables como x_3 (carga factorial de 0.77 en ML_1) y x_{16} (0.76 en ML_1) destacan significativamente, sugiriendo que la IA ha mejorado la calidad del trabajo académico y ha facilitado una mejor comprensión de los temas estudiados. Estos resultados señalan que la IA está desempeñando un papel clave en enriquecer la experiencia educativa y satisfacer las necesidades de aprendizaje de los estudiantes.
- Los estudiantes demostraron una confianza moderada a alta. Las variables x_6 y x_7 , ambas con cargas factoriales de 0.77 en ML_1 , reflejan que la facilidad de uso de las herramientas de IA está estrechamente ligada a su impacto positivo en el aprendizaje. Esta relación sugiere que, cuando las aplicaciones de IA son intuitivas y accesibles, los estudiantes no solo confían más en sus resultados, sino que también perciben mejoras en su rendimiento académico. La usabilidad emerge, por tanto, como un factor crítico en la adopción y efectividad de la IA en el entorno educativo.
- Por otro lado, el estudio identificó preocupaciones éticas que requieren atención. Variables como x_{19} (carga factorial de 0.81 en ML_2) y x_{20} (0.82 en ML_2) indican

inquietudes significativas respecto a la transparencia y la protección de la privacidad en el uso de la IA. Asimismo, x_{22} (0.70 en ML₂) resalta la importancia de la rendición de cuentas. Estos hallazgos ponen de manifiesto la necesidad de abordar estos aspectos éticos para fortalecer la confianza y aceptación de la IA entre los estudiantes. Garantizar prácticas transparentes y éticas es esencial para una integración responsable de estas tecnologías en la Educación Superior.

- El análisis de RLM demostró que el modelo final es estadísticamente significativo y explica aproximadamente el 49% de la variabilidad en la percepción positiva de la inteligencia artificial. Factores relacionados con la calidad de la experiencia al utilizar la IA, la facilidad de uso, la satisfacción con las herramientas, el impacto en el pensamiento crítico, la recomendación de su uso y la protección de la privacidad emergen como predictores clave de dicha percepción. Estos hallazgos, en línea con los objetivos propuestos, confirman la influencia determinante de estos factores en la valoración positiva de la IA en el ámbito educativo.
- Aunque la variable x_{12} no resultó significativa con estimación de -0.0692 y p-valor 0.1604, las demás variables aportan evidencias contundentes sobre los factores que influyen en la percepción positiva de la IA.
- Complementando con los resultados obtenidos de los docentes, el AFE indicó que los tres primeros factores principales explican conjuntamente el 70% de la varianza total en las respuestas. Variables como x_6 (carga factorial de 0.82 en ML₁) y x_4 (0.73 en ML₂) sugieren que la calidad de la experiencia y la mejora en la calidad del trabajo son aspectos relevantes para los docentes. Las preocupaciones éticas también fueron significativas, con variables como x_{20} (0.53 en ML₃) y x_{19} (0.61 en ML₃) destacando la importancia de la transparencia y la protección de la privacidad.
- El modelo final de RLM para los datos de docentes fue estadísticamente significativo F (4, 63) con 14.56 y p-valor de 1.791E-08 con un R² ajustado de 0.4473. Destacan variables como x_{16} con estimación de 0.3866 y p-valor de 0.0013, x_{19} con estimación de 0.2213 y p-valor de 0.0391, y x_{20} con estimación de 0.298 y p-valor de 0.0045*, indicando que el uso de herramientas de IA, la

protección de la privacidad y la transparencia son factores determinantes en la percepción positiva de la IA por parte de los docentes.

- En síntesis, los hallazgos del estudio permiten concluir que tanto estudiantes como docentes de las IES incluidas en este caso de estudio demuestran altos niveles de satisfacción con el aprendizaje mediado por inteligencia artificial, evidenciando una sólida confianza en los resultados que estas herramientas ofrecen en el proceso educativo.
- Por otro lado, se detectaron preocupaciones éticas relevantes, especialmente en términos de transparencia, protección de la privacidad y rendición de cuentas. Estas inquietudes destacan áreas críticas que requieren ser abordadas para garantizar una integración responsable y efectiva de la IA en el entorno de la Educación Superior.
- Finalmente, los resultados refuerzan la necesidad de impulsar estrategias formativas y programas de capacitación que aseguren que la implementación de la IA se realice de manera ética, transparente y centrada en las necesidades de estudiantes y docentes. Este enfoque permitirá maximizar el potencial de las tecnologías emergentes para enriquecer la educación y fomentar el desarrollo integral de los futuros profesionales.

Recomendaciones

- Las conclusiones indican que, dentro del grupo de IES analizadas en este caso de estudio, los estudiantes muestran una alta satisfacción en las dimensiones Académica y Desempeño, lo que refleja una percepción positiva del aprendizaje mediado por IA en este contexto específico. Es fundamental continuar fortaleciendo estas áreas mediante prácticas y políticas adaptadas a las características de las instituciones evaluadas, garantizando que los niveles de satisfacción se mantengan y potencien. Sin embargo, las dimensiones Tecnológica y Ética presentan mayor variabilidad, evidenciando preocupaciones relacionadas con la transparencia, la protección de la privacidad y la rendición de cuentas. Para

mejorar la percepción en estas áreas dentro de las instituciones analizadas, se recomienda realizar un análisis detallado para identificar las causas de esta variabilidad, desarrollar estrategias específicas como la actualización de recursos tecnológicos y la implementación de programas de capacitación en el uso de IA, además de fomentar prácticas éticas claras y consistentes que garanticen un uso responsable y transparente de estas herramientas.

- Los datos evidencian que la IA incrementa la calidad del trabajo, facilita la comprensión y mejora el rendimiento académico, y es valorada por su facilidad de uso. Para aprovechar estos beneficios y abordar las preocupaciones éticas, se propone integrar la IA en el currículo académico a través de módulos específicos sobre ética y uso responsable, que aborden la protección de datos, la transparencia en los algoritmos y la mitigación de sesgos. Se recomienda establecer protocolos éticos fiables, incluyendo auditorías periódicas de los sistemas de IA, la creación de comités de ética en cada institución y la adopción de normativas claras en materia de privacidad y rendición de cuentas. Asimismo, ofrecer capacitación especializada a estudiantes y docentes contribuirá a uniformar la comprensión de las implicaciones tecnológicas y éticas, fortaleciendo su confianza y competencia en el uso de la IA. En el caso de los docentes, es además crucial promover prácticas pedagógicas que integren la IA de manera transparente y responsable, demostrando sus beneficios para la calidad educativa sin comprometer los valores éticos.
- Las variables como la facilidad de uso, el impacto positivo en el aprendizaje y la recomendación del uso de IA tienen una influencia significativa en la percepción favorable de los estudiantes. Para maximizar estos beneficios, se debe potenciar estas áreas mediante el desarrollo y promoción de herramientas de IA más intuitivas y accesibles. Es fundamental destacar la contribución de la IA a la calidad del trabajo académico y al desarrollo del pensamiento crítico, reforzando su valor en el proceso educativo. Asimismo, es necesario abordar las áreas con menor familiaridad, como el grado de conocimiento y los aspectos confusos o poco intuitivos, proporcionando capacitaciones y soporte continuo que mejoren el entendimiento y uso efectivo de la IA.

- Para profundizar en la comprensión y mejorar la aplicación de la IA en la Educación Superior, se recomienda ampliar la investigación sobre su impacto, especialmente en variables que representan desafíos o ambigüedades en su uso. Aplicar métodos estadísticos robustos para manejar la heterogeneidad de varianzas mejorará la validez y confiabilidad de futuros estudios. Además, validar los hallazgos con muestras más amplias y diversas asegurará la generalización y aplicabilidad de los resultados en distintos contextos educativos.
- Las preocupaciones éticas y tecnológicas identificadas deben ser abordadas para fortalecer la confianza en la IA. Se propone desarrollar e implementar políticas institucionales que establezcan lineamientos claros para el uso de la IA, garantizando prácticas transparentes y éticas. Incorporar formación en ética y uso responsable de la IA tanto para estudiantes como para docentes es esencial, sensibilizando sobre la importancia de la privacidad, la transparencia y la rendición de cuentas. Además, promover prácticas pedagógicas de calidad que integren la IA eficazmente asegurará que su implementación responda a las necesidades educativas y contribuya al desarrollo integral de los estudiantes.
- Finalmente, es importante fomentar espacios de diálogo y colaboración entre estudiantes y docentes para compartir experiencias y buenas prácticas en el uso de la IA. Desarrollar proyectos y actividades conjuntas que integren la IA en el PEA fortalecerá el compromiso y la comprensión mutua. Evaluar continuamente el impacto de la IA en la educación permitirá ajustar estrategias y prácticas según los hallazgos y retroalimentación recibida, asegurando una adopción responsable y efectiva de estas tecnologías emergentes en beneficio de toda la comunidad educativa.

REFERENCIAS

- American Psychological Association [APA]. (2020). *Publication Manual of the American Psychological Association* (7.^a ed.). American Psychological Association.
- Aragón, R. (1 de septiembre de 2023). *Observatorio Educacion*. Inteligencia artificial en la educación: ¿Cómo mejora el aprendizaje?: <https://observatorioeducacion.es/lineas-investigacion/inteligencia-artificial-en-la-educacion/>
- Asamblea Nacional. (20 de octubre de 2008). *Constitución de la República del Ecuador. Registro Oficial No. 449*. <https://www.registroficial.gob.ec/index.php/registro-oficial-web/publicaciones/registro-oficial/item/4864-registro-oficial-no-449.html>
- Asamblea Nacional. (12 de octubre de 2010). *Ley Orgánica de Educación Superior. Registro Oficial Suplemento No. 298*. https://www.educacionsuperior.gob.ec/wp-content/uploads/downloads/2014/03/LEY_ORGANICA_DE_EDUCACION_SUPERIOR_LOES.pdf
- Asamblea Nacional. (9 de diciembre de 2016). *Código Orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación (Código Ingenios). Registro Oficial Suplemento No. 899*. <https://www.telecomunicaciones.gob.ec/wp-content/uploads/2016/12/CODIGO-ORGANICO-DE-LA-ECONOMIA-SOCIAL-DE-LOS-CONOCIMIENTOS.pdf>
- Asamblea Nacional. (26 de mayo de 2021). *Ley Orgánica de Protección de Datos Personales. Registro Oficial Suplemento No. 459*. <https://www.registroficial.gob.ec/index.php/registro-oficial-web/publicaciones/suplementos/item/14857-quinto-suplemento-al-registro-oficial-no-459>
- Avila-Tomás, J. F., Mayer-Pujadas, M. A., y Quesada-Varela, V. J. (2020). La inteligencia artificial y sus aplicaciones en medicina I: introducción antecedentes a la IA y robótica. *Atención Primaria*, 52(10), 778-784. <https://doi.org/10.1016/j.aprim.2020.04.013>

- Ayuga Téllez, E. (5 de mayo de 2008). *Análisis de datos multivariante*. Universidad Politécnica de Madrid [UPM]: https://moodle.upm.es/en-abierto/pluginfile.php/879/mod_label/intro/anal_mult_1.pdf
- Ayuso del Puerto, D., y Gutiérrez Esteban, P. (2022). La Inteligencia Artificial como recurso educativo durante la formación inicial del profesorado. *RIED-Revista Iberoamericana de Educación a Distancia*, 25(2), 347-358. <https://doi.org/10.5944/ried.25.2.32332>
- Baker, R., y Inventado, P. (2014). Educational Data Mining and Learning Analytics. En J. A. Larusson, & B. White, *Learning Analytics* (págs. 61–75). Springer. https://doi.org/10.1007/978-1-4614-3305-7_4
- Bartlett, M. S. (1950). Tests of significance in factor analysis. *British Journal of Statistical Psychology*, 3(2), 77-85. <https://doi.org/10.1111/j.2044-8317.1950.tb00285.x>
- Beauchamp, T. L., y Childress, J. F. (2019). *Principles of Biomedical Ethics* (8.^a ed.). Oxford University Press.
- Beneite-Martí, J. (13 de julio de 2023). Inteligencia artificial y educación: desafíos éticos de su aplicación. *III Congreso Internacional de Innovación y Tendencias Educativas (INNTEd 2023)*. <https://innted.org/ponencia/inteligencia-artificial-y-educacion-desafios-eticos-de-su-aplicacion/>
- Breusch, T. S., y Pagan, A. R. (1979). A Simple Test for Heteroskedasticity and Random Coefficient Variation. *Econometrica*, 47(5), 1287–1294. <https://doi.org/10.2307/1911963>
- Carbonell-García, C. E., Burgos-Goicochea, S., Calderón-de-los-Ríos, D. O., y Paredes-Fernández, O. W. (2023). La Inteligencia Artificial en el contexto de la formación educativa. *EPISTEME KOINONIA*, 6(12), 152–166. <https://doi.org/10.35381/e.k.v6i12.2547>
- Cattell, R. B. (1966). The scree test for the number of factors. *Multivariate Behavioral Research*, 1(2), 245–276. https://doi.org/10.1207/s15327906mbr0102_10
- CES. (25 de febrero de 2019). *Reglamento de Régimen Académico*. Quito, Ecuador. <https://www.ces.gob.ec/wp-content/uploads/2022/08/Reglamento-de-Re%CC%81gimen-Acade%CC%81mico-vigente-hasta-el-15-de-septiembre-de-2022.pdf>

- Chen, L., Chen, P., y Lin, Z. (2020). Artificial Intelligence in Education: A Review. *in IEEE Access*, 8, 75264 - 75278. <https://doi.org/10.1109/ACCESS.2020.2988510>
- China, C. R. (10 de enero de 2024). *Entienda las ventajas y las desventajas de la inteligencia artificial*. International Business Machines [IBM]: <https://www.ibm.com/mx-es/think/insights/artificial-intelligence-advantages-disadvantages>
- Cobo-Rendón, R., López-Angulo, Y., Sáez-Delgado, F., y Mella-Norambuena, J. (2022). Engagement, motivación académica y ajuste de estudiantado universitario. *Revista Electrónica Educare*, 26(3), 256-274. <https://doi.org/10.15359/ree.26-3.15>
- Cohen, L., Manion, L., y Morrison, K. (2018). *Research Methods in Education* (8th ed.). Routledge. <https://doi.org/10.4324/9781315456539>
- Costello, A. B., y Osborne, J. (2005). Best practices in exploratory factor analysis: four recommendations for getting the most from your analysis. *Practical Assessment Research & Evaluation*, 10(7), 1-9. <https://doi.org/10.7275/jyj1-4868>
- Council for International Organizations of Medical Sciences [CIOMS]. (2016). *International Ethical Guidelines for Health-related Research Involving Humans* (Cuarta ed.). Geneva: CIOMS publications.
- Crespo Campoverde, D., Campoverde Villata, J., Sánchez Bermeo, W., y Romero Córdova, D. (2023). Implementación de un Modelo de Regresión Lineal Múltiple aplicando (PLN) para predicción de artículos científicos. *ATENAS Revista Científica Técnica Y Tecnológica*, 2(1), 1-17. <https://doi.org/10.36500/atenas.2.008>
- Creswell, J. W., y Creswell, J. D. (2022). *Research Design Qualitative, Quantitative, and Mixed Methods Approaches*. Sage Publications.
- Cuban, L. (2001). *Oversold and Underused: Computers in the Classroom*. Harvard University Press. https://lets.cinvestav.mx/Portals/0/SiteDocs/MediatecaSS/lets_sur_mediateca_cuban_oversold.pdf
- Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3), 319-340. <https://doi.org/10.2307/249008>

- De la Fuente Fernández, S. (2011). *Portal Fuenterrebollo*.
<https://www.fuenterrebollo.com/Economicas/ECONOMETRIA/MULTIVARIANT E/FACTORIAL/analisis-factorial.pdf>
- Delgado, N., Campo Carrasco, L., Sainz de la Maza, M., y Etxabe-Urbieta, J. M. (2024). Aplicación de la Inteligencia Artificial (IA) en Educación: Los beneficios y limitaciones de la IA percibidos por el profesorado de educación primaria, educación secundaria y educación superior. *Revista Electrónica Interuniversitaria de Formación del Profesorado*, 27(1), 207–224.
<https://doi.org/10.6018/reifop.577211>
- D-Maps. (2025). *d-maps*. https://d-maps.com/carte.php?num_car=38868&lang=es
- Dúo Terrón, P., Moreno Guerrero, A. J., López Belmonte, J., y Marín Marín, J. A. (2023). Inteligencia Artificial y Machine Learning como recurso educativo desde la perspectiva de docentes en distintas etapas educativas no universitarias. *RiiTE Revista Interuniversitaria de Investigación en Tecnología Educativa*, 15, 58-78. <https://doi.org/10.6018/riite.579611>
- Durbin, J., y Watson, G. S. (1951). Testing for serial correlation in least squares regression. II. *Biometrika*, 38(1-2), 159-177.
<https://doi.org/10.1093/biomet/38.1-2.159>
- El Parlamento Europeo y el Consejo de la Unión Europea. (27 de abril de 2016). *General Data Protection Regulation*. <https://gdpr-info.eu/>
- Erbas, I., y Maksuti, E. (2024). The Impact of Artificial Intelligence on Education. *International Journal Of Innovative Research In Multidisciplinary Education [IJIRME]*, 3(4), 463 - 471. <https://doi.org/10.58806/ijirme.2024.v3i4n01>
- Ertmer, P. A., y Ottenbreit-Leftwich, A. T. (2010). Teacher Technology Change: How Knowledge, Confidence, Beliefs, and Culture Intersect. *Journal of Research on Technology in Education*, 42(3), 255–284.
<https://files.eric.ed.gov/fulltext/EJ882506.pdf>
- European Commission. (13 de octubre de 2017). *Guidelines on Data Protection Impact Assessment (DPIA) (wp248rev.01)*.
<https://ec.europa.eu/newsroom/article29/items/611236>
- Everitt, B. S. (2011). *Cluster Analysis* (5.^a ed.). John Wiley & Sons, Ltd.
- Fabrigar, L. R., y Wegener, D. T. (2012). Exploratory factor analysis. *Oxford University Press*. <https://psycnet.apa.org/record/2012-00696-000>

- Fajardo Aguilar, G. M., Ayala Gavilanes, D. C., Arroba Freire, E. M., y López Quincha, M. (2023). Inteligencia Artificial y la Educación Universitaria: Una revisión sistemática. *Magazine de las ciencias*, 8(1), 109-131. <https://doi.org/https://doi.org/10.33262/rmc.v8i1.2935>
- Fengchun, M., y Wayne, H. (2024). *Guía para el uso de IA generativa en educación e investigación*. UNESCO. <https://unesdoc.unesco.org/ark:/48223/pf0000389227>
- Field, A. (2018). *Discovering Statistics Using IBM SPSS Statistics*. SAGE edge. <http://repo.darmajaya.ac.id/5678/1/Discovering%20Statistics%20Using%20IBM%20SPSS%20Statistics%20%28%20PDFDrive%20%29.pdf>
- Flores-Rivera, L., y Meléndez-Tamayo, C. (2024). Estrategias de aprendizaje digital en entornos virtuales educativos. *Revista Innova Educación*, 6(2), 7-22. <https://doi.org/10.35622/j.rie.2024.02.001>
- Franganillo, J. (2023). La inteligencia artificial generativa y su impacto en la creación de contenidos mediáticos. *Revista De Ciencias Sociales*, 11(2), 1-17. <https://doi.org/10.17502/mrcs.v11i2.710>
- Freepik Company S.L. (28 de noviembre de 2023). *Encuesta sobre la IA en educación: la perspectiva de Slidesgo acerca de las herramientas de IA para educación*. slidesgo.com: <https://slidesgo.com/es/slidesgo-school/novedades/encuesta-sobre-la-ia-en-educacion-la-perspectiva-de-slidesgo-acerca-de-las-herramientas-de-ia-para-educacion>
- Gašević, D., Dawson, S., y Siemens, G. (2015). Let's not forget: Learning analytics are about learning. *TechTrends Tech Trends*, 59, 64-71. <https://doi.org/10.1007/s11528-014-0822-x>
- Genuine Digital School. (18 de abril de 2024). *Genuine School*. Inteligencia artificial en la educación: Optimizando el proceso de aprendizaje: <https://studyatgenuine.com/blog/inteligencia-artificial-en-la-educacion/>
- Genuine Digital School. (18 de abril de 2024). *Inteligencia artificial en la educación: Optimizando el proceso de aprendizaje*. <https://studyatgenuine.com/blog/inteligencia-artificial-en-la-educacion/>
- George, D., y Mallery, P. (2003). *SPSS for Windows Step by Step: A Simple Guide and Reference* (4.^a ed.). Allyn & Bacon.
- Ghasemi, A., y Zahediasl, S. (2012). Normality tests for statistical analysis: a guide for non-statisticians. *International Journal of Endocrinology and Metabolism*, 10(2), 486-489. <https://doi.org/10.5812/ijem.3505>

- González-González, C. S. (2023). El impacto de la inteligencia artificial en la educación: transformación de la forma de enseñar y de aprender. *Revista Currículum*(36), 51-60. <https://doi.org/10.25145/j.qurricul.2023.36.03>
- Google Cloud. (22 de abril de 2024). *¿Qué es la inteligencia artificial (IA)?* Definición de inteligencia artificial: <https://cloud.google.com/learn/what-is-artificial-intelligence?hl=es>
- Google Cloud. (2024). *Casos prácticos de IA generativa*. Genera texto, imágenes, código y más con la IA de Google Cloud: <https://cloud.google.com/use-cases/generative-ai?hl=es>
- Gostin, L. O., Halabi, S. F., y Wilson, K. (2018). Health Data and Privacy in the Digital Era. *JAMA*, 320(3). <https://doi.org/10.1001/jama.2018.8374>
- Gravetter, F. J., y Wallnau, L. B. (2016). *Statistics for the Behavioral Sciences* (Décima ed.). Cengage Learning.
- Hair Jr., J. F., Black, W. C., Babin, B. J., y Anderson, R. E. (2014). *Multivariate Data Analysis*. Pearson Education Limited.
- Hargreaves, A. (1995). *Changing teachers, changing times: Teachers' work and culture in the postmodern age*. RIE. <https://www.jstor.org/stable/23768992>
- Hauke, J., y Kossowski, T. (2011). Comparison of values of Pearson's and Spearman's correlation coefficients on the same sets of data. *Quaestiones Geographicae*, 30(2), 87-93. <https://doi.org/10.2478/v10117-011-0021-1>
- Hernández-Sampieri, R., y Mendoza Torres, C. P. (2018). *Metodología de la Investigación: Las rutas cualitativa, cuantitativa y mixta*. McGRAW-HILL INTERAMERICANA EDITORES, S.A. de C. V.
- Hinojo Lucena, F. J., Aznar Díaz, I., Romero Rodríguez, J. M., y Marín Marín, J. A. (2019). Influencia del aula invertida en el rendimiento académico. Una revisión sistemática. *Campus Virtuales*, 8(1), 9-18. <http://uajournals.com/ojs/index.php/campusvirtuales/article/view/384>
- Historioteca. (9 de noviembre de 2023). *Ética en la inteligencia artificial: desarrollo responsable*. <https://historioteca.com/etica-en-la-inteligencia-artificial-desarrollo-responsable/>
- Holmes, W., Bialik, M., y Fadel, C. (2019). *Artificial Intelligence In Education Promises and Implications for Teaching and Learning*. Center for Curriculum Redesign. <https://curriculumredesign.org/wp-content/uploads/AIED-Book-Excerpt-CCR.pdf>

- Howard, S. K., y Mozejko, A. (2015). Teachers: technology, change and resistance. En M. Henderson, y G. Romeo (Edits.), *Teaching and Digital Technologies: Big Issues and Critical Questions* (págs. 307-317). Port Melbourne, Australia: Cambridge University Press. <https://hdl.handle.net/10779/uow.27691038.v1>
- IBM Corporation. (30 de agosto de 2024). *Análisis factorial: Rotación*. SPSS Statistics: <https://www.ibm.com/docs/es/spss-statistics/saas?topic=analysis-factor-rotation>
- Instituto Nacional de Tecnologías Educativas y de Formación del Profesorado (INTEF). (2019). *El impacto de la Inteligencia Artificial en el aprendizaje, la enseñanza y la educación*. INTEF. <https://doi.org/10.2760/12297>
- Intel Corporation. (30 de octubre de 2023). *Tecnologías que facilitan la inteligencia artificial (IA) en la educación superior*. <https://www.intel.la/content/www/xl/es/education/highered/artificial-intelligence.html>
- Jimbo-Santana, P., Lanzarini, L. C., Jimbo-Santana, M., y Morales-Morales, M. (2023). Inteligencia artificial para analizar el rendimiento académico en instituciones de educación superior. Una revisión sistemática de la literatura. *Cátedra*, 6(2), 30–50. <https://doi.org/10.29166/catedra.v6i2.4408>
- Jolliffe, I. T., y Cadima, J. (2016). Principal component analysis: A review and recent developments. *Philosophical Transactions of the Royal Society A*, 374(2065). <https://doi.org/10.1098/rsta.2015.0202>
- Kaiser, H. F. (1960). The application of electronic computers to factor analysis. *Educational and Psychological Measurement*, 20(1), 141-151. <https://doi.org/10.1177/001316446002000116>
- Kaiser, H. F. (1974). An index of factorial simplicity. *Psychometrika*, 39(1), 31-36. <https://doi.org/10.1007/BF02291575>
- Kuckartz, U., Rädiker, S., Ebert, T., y Schehl, J. (2013). *Statistik: Eine verständliche Einführung*. VS Verlag für Sozialwissenschaften.
- Loján, M. D., Romero, J. A., Sancho Aguilera, D., y Romero, A. Y. (2024). Consecuencias de la Dependencia de la Inteligencia Artificial en Habilidades Críticas y Aprendizaje Autónomo en los Estudiantes. *Ciencia Latina Revista Científica Multidisciplinar*, 8(2), 2368-2382. https://doi.org/10.37811/cl_rcm.v8i2.10678

- López López, H. L., Rivera Escalera, A., y Cruz García, C. R. (2023). Personalización del aprendizaje con inteligencia artificial en la educación superior. *Revista Digital De Tecnologías Informáticas Y Sistemas*, 7(1), 123–128. <https://doi.org/10.61530/redtis.vol7.n1.2023.165.123-128>
- Luckin, R., Holmes, W., Griffiths, M., & Forcier, L. B. (2016). *Intelligence unleashed: An argument for AI in education*. Pearson. <https://www.pearson.com/content/dam/corporate/global/pearson-dot-com/files/innovation/Intelligence-Unleashed-Publication.pdf>
- Maldonado Zuñiga, K., Lucas Delgado, H. B., Vera Velázquez, R., y Cables Fernández, E. A. (2023). La inteligencia artificial y su impacto en la educación superior. *Serie Científica De La Universidad De Las Ciencias Informáticas*, 16(7), 204-215. <https://publicaciones.uci.cu/index.php/serie/article/view/1378>
- Maluenda Albornoz, J., Varas Contreras, M., Riffo Ferrada, M., y Díaz Mujica, A. (2021). Predictores socio-académicos del Study Engagement en estudiantes de primer año de ingeniería. *Estudios pedagógicos (Valdivia)*, 47(1), 235-250. <https://doi.org/10.4067/S0718-07052021000100235>
- Marimon, F., Arias Valle, M. B., Coria Augusto, C. J., y Larrea Arnau, C. M. (2025). Del optimismo a la confianza: el impacto de ChatGPT en la confianza de los estudiantes en el aprendizaje asistido por IA. *RIED-Revista Iberoamericana De Educación a Distancia*, 28(2), 1-20. <https://doi.org/10.5944/ried.28.2.43238>
- Martínez Ávila, M. (2021). Análisis factorial confirmatorio: un modelo de gestión del conocimiento en la universidad pública. *RIDE Revista Iberoamericana Para La Investigación Y El Desarrollo Educativo*, 12(23), 1-23. <https://doi.org/10.23913/ride.v12i23.1103>
- Meade, A. W., y Craig, S. B. (2012). Identifying careless responses in survey data. *Psychological Methods*, 17(3), 437-455. <https://doi.org/10.1037/a0028085>
- Meneses, J. (septiembre de 2019). *Introducción al análisis multivariante*. UOC [Universitat Oberta de Catalunya]: <https://openaccess.uoc.edu/bitstream/10609/148656/1/IntroduccionAnalisisMultivariante.pdf>
- Montero Granados, R. (2016). *Modelos de regresión lineal múltiple*. Documentos de Trabajo en Economía Aplicada: https://www.ugr.es/~montero/matematicas/regresion_lineal.pdf

- Montgomery, D. C., Peck, E. A., y Vining, G. G. (2012). *Introduction to linear regression analysis* (Quinta ed.). John Wiley & Sons, Inc.
https://www.kwcsangli.in/uploads/3--Introduction_to_Linear_Regression_Analysis__5th_ed._Douglas_C._Montgomery__Elizabeth_A._Peck__and_G._.pdf
- Muguirra, A. (23 de febrero de 2023). *¿Qué es la investigación descriptiva?*
<https://www.questionpro.com/blog/es/investigacion-descriptiva/>
- Multitrabajos. (15 de septiembre de 2023). *Multitrabajos*. <https://es.surveymonkey.com>
- Napkin AI. (2024). *napkin.ai*. app.napkin.ai: <https://app.napkin.ai>
- Novella García, L. G. (2023). La importancia de los Procesos de Aprendizaje para la formación y desarrollo del pensamiento crítico de futuros Líderes. *UPAEP Investigación*, 1-10.
https://investigacion.upaep.mx/micrositios/ebpd/assets/la_importancia_de_los_procesos.pdf
- O'Brien, R. M. (2007). A Caution Regarding Rules of Thumb for Variance Inflation Factors. *Quality & Quantity*, 41(5), 673-690. <https://doi.org/10.1007/s11135-006-9018-6>
- Observatorio Argentino de Drogas [OAD]. (2 de febrero de 2022). *argentina.gob.ar*.
https://www.argentina.gob.ar/sites/default/files/oad_cartilla_2_modelos_consentimiento_informado_para_cuestionarios_entrevistas_y_grupos_focales_0.pdf
- Office for Human Research Protections [OHRP]. (1979). *The Belmont Report: Ethical Principles and Guidelines for the Protection of Human Subjects of Research. National Commission for the Protection of Human Subjects of Biomedical and Behavioral Research*. Protecting Human Subjects in Research.
- Organización de las Naciones Unidas [ONU]. (2015). *Objetivos de Desarrollo Sostenible*. <https://www.un.org/sustainabledevelopment/es/objetivos-de-desarrollo-sostenible/>
- Organización para la Cooperación y el Desarrollo Económico [OECD]. (mayo de 2021). *OECD Economic Outlook* (Vol. 2021). Paris: OECD Publishing.
<https://doi.org/https://doi.org/10.1787/edfbca02-en>
- Ortega, C. (23 de febrero de 2023). *¿Qué es el muestreo por conveniencia?* Software para encuestas Questionpro: <https://www.questionpro.com/blog/es/muestreo-por-conveniencia/>

- Ortega, C. (23 de febrero de 2023). *¿Qué es un estudio transversal?*
<https://www.questionpro.com/blog/es/estudio-transversal/>
- Ortega, C. (4 de julio de 2023). *Muestreo casual o accidental: Qué es y cómo se realiza.*
<https://www.questionpro.com/blog/es/muestreo-casual-o-accidental/#:~:text=%C2%BFQu%C3%A9%20es%20un%20muestreo%20casual,de%20un%20c%C3%A1culo%20m%C3%A1s%20cuidadoso.>
- Oviedo, H. C., y Campo-Arias, A. (2005). Aproximación al uso del coeficiente alfa de Cronbach. *Revista Colombiana de Psiquiatría*, 34(4). <https://doi.org/572-580>
- Pardo, A., y Ruiz, M. Á. (2005). *Análisis de datos con SPSS 13 Base*. McGraw-Hill / Interamericana de España S. A. U.
- Parra, A. (7 de febrero de 2023). *Muestreo intencional. Características y ejemplos.*
<https://www.questionpro.com/blog/es/muestreo-intencional/#:~:text=El%20muestreo%20intencional%20es%20una,que%20formar%C3%A1n%20parte%20del%20estudio.>
- Pearson. (5 de septiembre de 2023). *Docentes liderando con Inteligencia Artificial en la educación*. Higher Education: <https://blog.pearsonlatam.com/educacion-del-futuro/docentes-liderando-con-inteligencia-artificial-en-la-educacion>
- Peñaherrera Acurio, W. P., Cunuhay Cuchipe, W. C., Nata Castro, D. J., y Moreira Zamora, L. E. (2022). Implementación de la Inteligencia Artificial (IA) como Recurso Educativo. *RECIMUNDO*, 6(2), 402-413. [https://doi.org/10.26820/recimundo/6.\(2\).abr.2022.402-413](https://doi.org/10.26820/recimundo/6.(2).abr.2022.402-413)
- Pérez, E. R., y Medrano, L. (2010). Análisis factorial exploratorio: bases conceptuales y metodológicas. *Revista Argentina de Ciencias del Comportamiento*, 2(1), 58-66. <https://doi.org/10.32348/1852.4206.v2.n1.15924>
- Puertas, E. (2023). Inteligencia Artificial Generativa. *Universidad Europea de Madrid UEM STEAM*, 1-8. https://universidadeuropea.com/resources/media/documents/28_STEAM_GENERATIVE_AI_RZII.pdf
- Qualtrics. (2023). *Qualtrics XM Platform*. <https://www.qualtrics.com/>
- Ramos Armijos, D. F., Ramos Armijos, N. J., Tapia Puga, V. M., y Tapia Puga, L. I. (2024). Explorando las Fronteras: la Aplicación de Inteligencia Artificial en la Evaluación Educativa. *Ciencia Latina Revista Científica Multidisciplinar*, 7(6), 5657-5672. https://doi.org/10.37811/cl_rcm.v7i6.9108

- Ramos, G. (22 de abril de 2024). *Ética de la inteligencia artificial*. <https://www.unesco.org/es/artificial-intelligence/recommendation-ethics>
- Resnik, D. B. (2018). *The Ethics of Research with Human Subjects: Protecting People, Advancing Science, Promoting Trust*. Springer. <https://doi.org/10.1007/978-3-319-68756-8>
- Revelle, W. (2017). *psych: Procedures for Psychological, Psychometric, and Personality Research*. Northwestern Scholars: https://personality-project.org/r/psych/HowTo/psych_manual.pdf
- Rico Páez, A., y Gaytán Ramírez, N. D. (2022). Modelos predictivos del rendimiento académico a partir de características de estudiantes de ingeniería. *IE Revista De Investigación Educativa De La REDIECH*, 13, 1-18. https://doi.org/10.33010/ie_rie_rediech.v13i0.1426
- Rivas, A., Buchbinder, N., y Barrenechea, I. (2023). *El futuro de la Inteligencia Artificial en educación en América Latina*. ProFuturo y la Organización de Estados Iberoamericanos para la Educación, la Ciencia y la Cultura (OEI). <https://oei.int/downloads/disk/eyJfcMfPbHMiOmsibWVzc2FnZSI6IkJBaDdDRG9JYTJWNVNTSWhaMIZ0ZG1Wc04zRm9NR3RwZHpOMU1HRjJZbmhoYlhcCmNEVmtaUVk2QmtWVU9oQmthWE53YjNOcGRHbHZia2tpQWRacGJteHBibVU3SUdadcGJHVnVZVzFsUFNKRmJDQm1kWF1xY204Z1pHVWdiR0VnYVc1MFpXeHBaMIZ1WTJsaEIH>
- Rock Content. (27 de marzo de 2020). *Descubre cómo la transformación digital ocurre en la educación superior y sus impactos para la sociedad*. <https://rockcontent.com/es/blog/transformacion-digital-en-la-educacion-superior/>
- Romero, C., y Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *WIREs Data Mining Knowl Discov*, 10:e1355, 1-21. <https://doi.org/10.1002/widm.1355>
- Romero, J. (1 de enero de 2020). *Prueba de Kaiser-Meyer-Olkin (KMO)*. r-data-scientist.com: <https://www.r-data-scientist.com/es/blog/statistical-tests/kaiser-meyer-olkin-test/>
- Rus Arias, E. (e de febrero de 2021). *Investigación descriptiva: Qué es, tipos y ejemplos*. <https://economipedia.com/definiciones/investigacion-descriptiva.html>
- Salmerón Moreira, Y. M., Luna Alvarez, H. E., Murillo Encarnacion, W. G., y Pacheco Gómez, V. A. (2023). El futuro de la Inteligencia Artificial para la educación en

- las instituciones de Educación Superior. *Revista Conrado*, 19(93), 27–34.
<https://conrado.ucf.edu.cu/index.php/conrado/article/view/3156>
- Secretaría de Educación Superior, Ciencia, Tecnología e Innovación [SENESCYT]. (22 de septiembre de 2023). *Portal de Estadísticas e Indicadores de Educación Superior*. <https://siau.senescyt.gob.ec/universidades-y-escuelas-politecnicas-matriculas/>
- Secretaría Nacional de Planificación. (2024). *Elaboración del Plan de Desarrollo para el Nuevo Ecuador 2024 - 2025*. Gráficas IMAGO Cía. Ltda. <https://www.planificacion.gob.ec/wp-content/uploads/2024/02/PND2024-2025.pdf>
- Selwyn, N. (2019). *Should robots replace teachers? AI and the Future of Education*. Polity Press.
- Servicio de Psicología Clínica del Desarrollo [Psise]. (31 de agosto de 2023). *Procesos de aprendizaje*. <https://psisemadrid.org/procesos-de-aprendizaje/>
- Shapiro, S. S., y Wilk, M. B. (1965). An analysis of variance test for normality (complete samples). *Biometrika*, 52(3-4), 591-611. <https://doi.org/10.2307/2333709>
- SixSigma.us. (31 de julio de 2024). *A Complete Guide to the Anderson-Darling Normality Test*. Articles: <https://www.6sigma.us/six-sigma-in-focus/anderson-darling-normality-test/>
- Software para encuestas QuestionPro. (2023). *Investigación de campo*. <https://www.questionpro.com/es/investigacion-de-campo.html#:~:text=Es%20un%20m%C3%A9todo%20de%20recolecci%C3%B3n,las%20personas%20que%20est%C3%A1n%20estudiando.>
- Spearman, C. (1904). The proof and measurement of association between two things. *The American Journal of Psychology*, 15(1), 72-101. <https://doi.org/https://doi.org/10.2307/1412159>
- Stevens, J. P. (2009). *Applied multivariate statistics for the social sciences*. Taylor & Francis Group, LLC.
- Stewart, L. (10 de julio de 2024). *Datos primarios: Definición, ejemplos y métodos de recogida*. ATLAS.ti: <https://atlasti.com/es/research-hub/datos-primarios>
- Tabachnick, B. G., y Fidell, L. S. (2013). *Using Multivariate Statistics*. Pearson Education, Inc. https://hispania.ch/pluginfile.php/77114/mod_resource/content/0/Using%20Multivariate%20Statistics%20%28Tabachnick%20and%20Fidell%29.pdf

- The R Foundation. (2023). *R: A Language and Environment for Statistical Computing*.
<https://www.r-project.org/>
- Tinoco-Izquierdo, W. E., y Tinoco-Cuenca, N. P. (2018). El proceso de enseñanza aprendizaje en la educación superior: aprender para aprender durante toda la vida. *Maestro y sociedad*, 15(3), 409-419.
<https://maestroysociedad.uo.edu.cu/index.php/MyS/article/download/4000/3454/>
- Tomalá De La Cruz, M. A., Mascaró Benites, E. M., Carrasco Cachinelli, C. G., y Aroni Caicedo, E. V. (2023). Incidencias de la inteligencia artificial en la educación. *RECIMUNDO*, 7(2), 238-251.
[https://doi.org/10.26820/recimundo/7.\(2\).jun.2023.238-251](https://doi.org/10.26820/recimundo/7.(2).jun.2023.238-251)
- Toro, R., Peña-Sarmiento, M., Bertha Lucía Avendaño-Prieto, B. L., Mejía-Vélez, S., y Bernal-Torres, A. (2022). Análisis Empírico del Coeficiente Alfa de Cronbach según Opciones de Respuesta, Muestra y Observaciones Atípicas. *Revista Iberoamericana de Diagnóstico y Evaluación – e Avaliação Psicológica. RIDEP*, 2(63), 17-30. <https://doi.org/10.21865/RIDEP63.2.02>
- Torra i Reventós, V. (18 de septiembre de 2019). *Qué es la inteligencia artificial*.
<https://openaccess.uoc.edu/bitstream/10609/148039/3/QueEsLaInteligenciaArtificial.pdf>
- UNESCO. (2021). *Inteligencia artificial y educación: guía para las personas a cargo de formular políticas*. Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura [UNESCO].
<https://unesdoc.unesco.org/ark:/48223/pf0000379376>
- UNESCO. (2021). *Recomendación sobre la ética de la inteligencia artificial*. Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO). Ética de la inteligencia artificial:
https://unesdoc.unesco.org/ark:/48223/pf0000381137_spa
- UNESCO. (24 de abril de 2023). *Inteligencia artificial: ejemplos de dilemas éticos*.
<https://www.unesco.org/es/artificial-intelligence/recommendation-ethics/cases>
- VanLehn, K. (2011). The relative effectiveness of human tutoring, intelligent tutoring systems, and other tutoring systems. *Educational Psychologist*, 46(4), 197–221.
<https://doi.org/10.1080/00461520.2011.611369>
- Velázquez, A. (19 de junio de 2023). *¿Qué es el muestreo de bola de nieve?*
<https://www.questionpro.com/blog/es/muestreo-de-bola-de-nieve/>

- Velázquez, A. (3 de julio de 2023). *¿Qué es el muestreo por cuotas?* Software para encuestas Questionpro: [view-source:https://www.questionpro.com/blog/es/muestreo-por-cuotas/](https://www.questionpro.com/blog/es/muestreo-por-cuotas/)
- Wickham, H. (2016). *ggplot2: Elegant Graphics for Data Analysis*. Springer.
- World Medical Association [WMA]. (octubre de 2024). *WMA Declaration of Helsinki – Ethical Principles for Medical Research Involving Human Subjects*. <https://www.wma.net/policies-post/wma-declaration-of-helsinki/>
- Yap, B. W., y Sim, C. H. (2011). Comparisons of various types of normality tests. *Journal of Statistical Computation and Simulation*, 81(12), 2141-2155. <https://doi.org/10.1080/00949655.2010.520163>
- Zamora Varela, Y. ..., y Mendoza Encinas, M. d. (2023). La Inteligencia artificial y el futuro de la educación superior: desafíos y oportunidades. *Horizontes pedagógicos*, 25(1), 1-13. <https://doi.org/10.33881/0123-8264.hop.25101>
- Zawacki-Richter, O., Marín, V. I., Bond, M., y Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*, 16(39), 1-27. <https://doi.org/10.1186/s41239-019-0171-0>

ANEXOS

Anexo A. Certificado del abstract por parte de idiomas



UNIVERSIDAD POLITÉCNICA ESTATAL DEL CARCHI- FOREIGN AND NATIVE LANGUAGES CENTER

Informe sobre el Abstract de Artículo Científico o Investigación.

Autor: Luis Danilo Flores Rivera

Fecha de recepción del abstract: Lunes, 7 de julio de 2025

Fecha de entrega del informe: Lunes, 7 de julio de 2025

El presente informe validará la traducción del idioma español al inglés si alcanza un porcentaje de: 9 – 10 Excelente.

Si la traducción no está dentro de los parámetros de 9 – 10, el autor deberá realizar las observaciones presentadas en el ABSTRACT, para su posterior presentación y aprobación.

Observaciones:

Después de realizar la revisión del presente abstract, éste presenta una apropiada traducción sobre el tema planteado en el idioma Inglés. Según la rúbrica de evaluación de la traducción en Inglés, ésta alcanza un valor de 9; por lo cual se valida dicho trabajo.

Atentamente



MA. Martha Viveros
Docente responsable del
CIDEN

Anexo B. Cuestionario

UNIVERSIDAD POLITÉCNICA ESTATAL DEL CARCHI POSGRADO MAESTRÍA EN ESTADÍSTICA APLICADA

Encuesta dirigida a estudiantes y docentes de la Educación Superior que utilizan programas y sistemas con Inteligencia Artificial para sus actividades de aprendizaje y enseñanza.

El presente cuestionario tiene como objetivo contar con información del impacto de la aplicación de inteligencia artificial (IA) en el proceso de aprendizaje de estudiantes de educación superior. Esta encuesta es anónima y los datos proporcionados serán tratados de manera confidencial. Al iniciar la encuesta, usted indica que ha leído y comprendido la información proporcionada y que acepta participar en esta encuesta.

Por tanto, la contestación a este cuestionario es una importante colaboración al proyecto de investigación de la Maestría en Estadística Aplicada de la UPEC.

INSTRUCTIVO:

- Seleccione una de las alternativas que se propone.
- Marque con una X en la casilla la alternativa que usted eligió; salvo el caso particular de que una/s pregunta/s se le pida elegir una o varias alternativas.

DATOS GENERALES:

Género: M F Prefiero no decirlo

Miembro académico: Estudiante Docente

Nivel de formación:

Nivel de educación superior alcanzado:

- Primer año (1 - 2 nivel)
- Segundo año (3 - 4 nivel)
- Tercer año (5 - 6 nivel)
- Cuarto año (7 - 8 nivel)
- Quinto año (9 - 10 nivel)
- Sexto año (11 - 12 nivel)

- Superior (Técnica/Tecnólogo)
- Superior (Licenciatura/Títulos profesionales universitarios o politécnicos y sus equivalentes)
- Posgrado (Especialización)
- Posgrado (Maestría)
- Posgrado (Doctorado/Ph.D.)
- Posgrado (Postdoctorado)

DATOS DEMOGRÁFICOS:

Edad: Área de conocimiento en ejercicio o formación

- | | | |
|-------------------------------------|--|--|
| <input type="radio"/> Entre 18 y 25 | <input type="radio"/> Programas Genéricos y Calificaciones | <input type="radio"/> Información y Comunicación (TIC) |
| <input type="radio"/> Entre 26 y 35 | <input type="radio"/> Educación | <input type="radio"/> Ingeniería, Industria y Construcción |
| <input type="radio"/> Entre 36 y 45 | <input type="radio"/> Artes y Humanidades | <input type="radio"/> Agricultura, Silvicultura, Pesca y Veterinaria |
| <input type="radio"/> Entre 46 y 60 | <input type="radio"/> Ciencias Sociales, Periodismo e Información | <input type="radio"/> Salud y Bienestar |
| <input type="radio"/> Más de 60 | <input type="radio"/> Administración, Negocios y Legislación | <input type="radio"/> Servicios |
| | <input type="radio"/> Ciencias Físicas, Ciencias Naturales, Matemáticas y Estadísticas | |

¿La institución de educación superior en la que estudias o laboras es pública o privada?

- Pública
- Privada

¿En qué provincia se encuentra ubicada tu Institución de Educación Superior en la que estudias o laboras?

- | | | |
|----------------------------------|---------------------------------------|--|
| <input type="radio"/> Azuay | <input type="radio"/> Galápagos | <input type="radio"/> Orellana |
| <input type="radio"/> Bolívar | <input type="radio"/> Guayas | <input type="radio"/> Pastaza |
| <input type="radio"/> Cañar | <input type="radio"/> Imbabura | <input type="radio"/> Pichincha |
| <input type="radio"/> Carchi | <input type="radio"/> Loja | <input type="radio"/> Santa Elena |
| <input type="radio"/> Chimborazo | <input type="radio"/> Los Ríos | <input type="radio"/> Santo Domingo de los Tsáchilas |
| <input type="radio"/> Cotopaxi | <input type="radio"/> Manabí | <input type="radio"/> Sucumbios |
| <input type="radio"/> El Oro | <input type="radio"/> Morona Santiago | <input type="radio"/> Tungurahua |
| <input type="radio"/> Esmeraldas | <input type="radio"/> Napo | <input type="radio"/> Zamora Chinchipe |

DIMENSIÓN: ACADÉMICO

1. ¿Has utilizado herramientas IA?

- Sí
- No

2. ¿La utilización de la IA es sencilla y perceptible?
- Totalmente en desacuerdo desacuerdo Ni de acuerdo ni en desacuerdo De acuerdo Totalmente de acuerdo
3. ¿La utilización de herramientas IA en el aprendizaje es positiva?
- Totalmente en desacuerdo desacuerdo Ni de acuerdo ni en desacuerdo De acuerdo Totalmente de acuerdo
4. ¿La IA está mejorando la calidad del trabajo frecuente?
- Totalmente en desacuerdo desacuerdo Ni de acuerdo ni en desacuerdo De acuerdo Totalmente de acuerdo
5. ¿Cuál es la razón principal por la que utilizas IA en la educación? (Escoja una o varias alternativas).
- Generar contenido como textos, imágenes, presentaciones, videos
 - Mejorar texto y/o redacción (parafraseo)
 - Automatizar tareas repetitivas
 - Consultas o inquietudes diarias
 - Inspirarse para preparar o realizar tareas
 - Traducir textos a otros idiomas
 - Revisar índice de similitud o plagio
 - Organizar actividades
 - Ahorrar tiempo
 - Otra ¿Cuál? _____
6. ¿Cómo calificas tu experiencia al usar IA?
- Muy mala Mala Regular Buena Muy buena
7. Recomendarías el uso de IA para el proceso enseñanza aprendizaje.
- Totalmente en desacuerdo desacuerdo Ni de acuerdo ni en desacuerdo De acuerdo Totalmente de acuerdo

DIMENSIÓN: TECNOLÓGICA

8. ¿Qué asistente (Chatbots) IA has utilizado para tus clases? (Escoja una o varias alternativas).
- ChatGPT
 - Copilot
 - Gemini (Bard)
 - Claude
 - Elicit
 - Perplexity
 - Jasper Chat
 - Otro ¿Cuál? _____
9. ¿Cuánto tiempo a la semana utilizas la IA para tus actividades educativas?
- Menos de 10 horas
 - 10 a 20 horas
 - 21 a 30 horas
 - 31 a 40 horas
 - Más de 40 horas
10. ¿Has encontrado aspectos confusos o poco intuitivos al usar herramientas IA?
- Totalmente en desacuerdo desacuerdo Ni de acuerdo ni en desacuerdo De acuerdo Totalmente de acuerdo
11. ¿Has encontrado errores en el uso de herramientas IA?
- Si
 - No
12. ¿Cómo calificas tu grado de conocimiento al usar IA?
- Muy malo Malo Regular Bueno Muy bueno

DIMENSIÓN: DESEMPEÑO

13. ¿Lograron las herramientas IA satisfacer tus expectativas?

Totalmente en desacuerdo	desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

14. ¿Crees que la IA ha impactado en el desarrollo del pensamiento crítico en el proceso de aprendizaje?

Totalmente en desacuerdo	desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

15. ¿Consideras que el uso de la IA facilita la comprensión y consecuentemente el rendimiento?

Totalmente en desacuerdo	desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

16. ¿Le parece conveniente el uso de herramientas IA en apoyo de actividades académicas?

Totalmente en desacuerdo	desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

17. ¿Qué habilidades consideras mejorar a través de las herramientas de IA? (Escoja una o varias alternativas).

- Búsqueda de información
- Selección de información relevante
- Capacidad de concreción de ideas
- Modificación de parámetros de búsqueda
- Aprendizaje de distintos temas
- Agilizar procesos para enfocarse en otras temáticas
- Aprendizaje de otro idioma
- Otro ¿Cuál? _____

DIMENSIÓN: ÉTICA

¿Consideras que la IA?

	Totalmente en desacuerdo	desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
18. Puede respetar los principios éticos y los derechos humanos en la educación	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
19. Puede proteger la privacidad y la seguridad de los datos educativos	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
20. Puede garantizar la transparencia y la rendición de cuentas de sus procesos y resultados	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
21. Puede ser crítica y reflexiva sobre sus limitaciones y riesgos	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
22. Cuenta con lineamientos claros para el uso de herramientas IA	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

23. ¿Citas o referencias el uso de herramientas IA en tus trabajos académicos?

- Sí
- No

24. ¿Considera necesario generar y difundir lineamientos claros del uso de herramientas IA?

- Sí
- No

2b. ¿Por qué no has utilizado herramientas de IA?

- No conozco ninguna herramienta de IA
- No creo que sean útiles para mí
- No sé cómo usarlas
- Prefiero métodos tradicionales
- No tengo tiempo para aprender a usarlas
- Otra ¿Cuál? _____

¡Gracias por su colaboración!