

Artículo de Investigación

Análisis de estrategias innovadoras para retención estudiantil con inteligencia artificial: una perspectiva multidisciplinaria

Analysis of Innovative Strategies for Student Retention with Artificial Intelligence: A Multidisciplinary Perspective

Ester Martín-Caro Álamo: Instituto Europeo de Posgrado, España.
emartincaro@iep.edu.es

Fecha de Recepción: 15/05/2024

Fecha de Aceptación: 16/07/2024

Fecha de Publicación: 30/07/2024

Cómo citar el artículo (APA 7^a):

Martín-Caro, E. (2024). Análisis de estrategias innovadoras para retención estudiantil con inteligencia artificial: una perspectiva multidisciplinaria [Analysis of Innovative Strategies for Student Retention with Artificial Intelligence: A Multidisciplinary Perspective]. *European Public & Social Innovation Review*, 9, 1.-20. <https://doi.org/10.31637/epsir-2024-440>

Resumen:

Introducción: La educación superior está transformándose con la adopción de modalidades virtuales e integración de tecnologías como la inteligencia artificial (IA), machine learning (ML), redes neuronales (NN) y big data (BD). Estas tecnologías están redefiniendo el acceso y la retención estudiantil, ofreciendo soluciones personalizadas para mejorar la experiencia educativa en entornos virtuales. **Metodología:** Esta revisión sistemática, basada en el método PRISMA, examina cómo la interacción de IA, ML, NN y BD influye en la predicción y gestión de la deserción estudiantil, destacando las aplicaciones de learning analytics (LA) para mejorar las intervenciones educativas. **Resultados:** Los resultados muestran que IA, ML y BD son efectivas para prever y gestionar el abandono escolar, permitiendo intervenciones más personalizadas. El análisis de grandes volúmenes de datos ayuda a identificar patrones cruciales para diseñar estrategias de retención. **Discusión:** A pesar de las mejoras significativas en la personalización del aprendizaje y optimización de recursos que ofrecen estas tecnologías, enfrentan desafíos éticos y operativos que deben considerarse. **Conclusiones:** La integración de IA, ML, NN y BD en la educación superior es un enfoque prometedor para enriquecer la experiencia y resultados estudiantiles, destacándose la importancia de inversiones estratégicas y un marco ético robusto para su implementación efectiva.

Palabras clave: educación superior; inteligencia artificial; machine learning; redes neuronales; big data; learning analytics; retención estudiantil; revisión sistemática.

Abstract:

Introduction: Higher education is transforming with the adoption of virtual modalities and the integration of technologies such as artificial intelligence (AI), machine learning (ML), neural networks (NN), and big data (BD). These technologies are redefining access and student retention, offering personalized solutions to enhance the educational experience in virtual environments. **Methodology:** This systematic review, based on the PRISMA method, examines how the interaction of AI, ML, NN, and BD influences the prediction and management of student dropout, highlighting the applications of learning analytics (LA) to improve educational interventions. **Results:** The results show that AI, ML, and BD are effective in predicting and managing school dropout, allowing for more personalized interventions. Analyzing large volumes of data helps identify crucial patterns for designing retention strategies. **Discussion:** Despite the significant improvements in personalized learning and resource optimization offered by these technologies, they face ethical and operational challenges that must be considered. **Conclusions:** The integration of AI, ML, NN, and BD in higher education is a promising approach to enriching the student experience and outcomes, emphasizing the importance of strategic investments and a robust ethical framework for effective implementation.

Keywords: higher education; artificial intelligence; machine learning; neural networks; big data; learning analytics; student retention; systematic review.

1. Introducción

La educación superior está experimentando una transformación profunda, impulsada por la adopción de la modalidad virtual que están redefiniendo y democratizando el acceso a la educación (Guzmán *et al.*, 2022; Segovia-García, 2022). Este cambio ha conllevado numerosos desafíos y oportunidades para las instituciones de educación superior, que se han visto obligadas a redefinir los métodos y estrategias pedagógicas para satisfacer las necesidades de una población estudiantil cada vez más diversa y garantizar que la educación sea accesible y eficaz para todos, independientemente de su ubicación geográfica o situación personal (Segovia-García y Said-Hung, 2021).

Lo anterior ha implicado el incremento de la deserción estudiantil, un fenómeno que impacta negativamente el futuro académico y profesional de los estudiantes y la sostenibilidad de las instituciones, siendo más acuciante en la modalidad virtual donde la tasa de abandono es más alta en comparación con las modalidades presencial o híbrida (Orellana *et al.*, 2020). Los factores que influyen en la deserción estudiantil han sido extensamente estudiados en la literatura, destacando investigaciones pioneras como las de Tinto (1987), y estudios más recientes como los desarrollados por Salam y Farooq (2020), Orellana *et al.* (2020), Segovia-García y Said-Hung (2021), Segovia-García *et al.* (2022), y Quecano *et al.* (2024), entre otros. Estos estudios abarcan una amplia gama de causas relacionadas con el abandono educativo, desde el rendimiento académico hasta problemas económicos y la falta de soporte social. En cualquier caso, la comunidad académica ha subrayado la necesidad de implementar intervenciones efectivas para mejorar la retención estudiantil.

En consecuencia, la implementación de estrategias de retención estudiantil por parte de las instituciones educativas se vuelve crucial, no solo para mejorar los resultados académicos y la satisfacción de los estudiantes, sino también para elevar la eficiencia institucional. Estrategias como la oferta de tutorías personalizadas, soporte psicológico, acceso a recursos económicos y la creación de comunidades de aprendizaje que fomenten vínculos más profundos y apoyo mutuo entre estudiantes son esenciales. Estas acciones están alineadas con los hallazgos de investigaciones previas como Segovia-García y Said-Hung (2021), quienes demostraron la importancia de un enfoque integral en la retención estudiantil. Además, estas prácticas no solo enriquecen la experiencia educativa, sino que también transforman la calidad de la educación y fortalecen la viabilidad financiera de las instituciones, como lo sugieren Segovia-García y Martín-Caro (2023).

Dentro del panorama de diseño de estrategias para lograr la retención, la inteligencia artificial (IA) emerge como una solución para prevenir y mitigar el abandono estudiantil en la educación superior. Así, la IA puede analizar grandes volúmenes de datos sobre el comportamiento y rendimiento de los estudiantes, facilitando que las instituciones puedan anticipar tendencias y necesidades. Esto permite ajustar las estrategias pedagógicas y de soporte para mejorar la retención y los resultados académicos, tal y como recogen los hallazgos de Albreiki (2022), Figueroa-Cañas y Sancho-Vinuesa (2020), Singh *et al.* (2023) y Tang *et al.* (2023); o, personalizar el aprendizaje, adaptándolo al ritmo y estilo de cada estudiante, lo que potencialmente mejora el rendimiento académico y la satisfacción estudiantil (Bulut *et al.*, 2022; Jongile y Ivala, 2023; Ifenthaler y Yau, 2020).

Incorporar la Inteligencia Artificial (IA) en las estrategias de retención estudiantil no solo alinea a las instituciones con las innovaciones tecnológicas actuales, sino que también les permite crear un entorno más inclusivo y accesible, asegurando que todos los estudiantes, independientemente de su ubicación geográfica o circunstancias personales, tengan la oportunidad de triunfar y completar sus estudios. El uso de *Machine Learning* (ML), Redes Neuronales (NN) y *Big Data* (BD) en particular, ofrece capacidades avanzadas para el análisis y la predicción de patrones de comportamiento estudiantil que son fundamentales para desarrollar intervenciones proactivas y personalizadas. Estas herramientas permiten a las instituciones educativas no solo reaccionar a las tendencias existentes, sino también anticipar y mitigar posibles causas de deserción antes de que afecten el rendimiento o la satisfacción del estudiante. Además, la *Learning Analytics* (LA) facilita una comprensión más profunda de las necesidades de aprendizaje y los obstáculos individuales, lo que mejora significativamente la precisión de las intervenciones educativas.

Consecuentemente, este artículo se enfoca en realizar una revisión exhaustiva de la literatura sobre las aplicaciones de la IA en el ámbito de la retención estudiantil. Esta perspectiva innovadora representa un primer esfuerzo por sintetizar la evidencia sobre el uso de estas herramientas en relación con la retención estudiantil, con el objetivo de analizar diversas estrategias implementadas en pro de la mejora de la tasa de retención. Para abordar esta investigación de manera sistemática, se plantean las siguientes preguntas de investigación (RQ):

- RQ1: ¿Cómo ha evolucionado la investigación en torno a la IA y sus aplicaciones en el ámbito de investigación relacionado con el abandono y la retención educativa?
- RQ2: ¿De qué manera pueden las tecnologías de información y análisis de datos ser empleados para identificar y abordar los factores de riesgo de abandono en la educación superior antes de que comprometan el rendimiento académico de los estudiantes?
- RQ3: ¿Cuáles son los desafíos éticos y operativos más significativos que enfrenta la implementación de la IA en la retención estudiantil, especialmente en entornos de educación superior?

1.1. Definición de Retención Estudiantil y como se analiza este fenómeno en la educación superior

La retención estudiantil en la educación superior se refiere a la capacidad de las instituciones de mantener a sus estudiantes desde el inicio de sus estudios hasta la finalización de su programa académico, evitando la deserción escolar. Este concepto implica no solo la permanencia de los estudiantes en la institución, sino también su progreso continuo y satisfactorio hacia la obtención de su grado académico.

El análisis de la retención estudiantil en la educación superior puede abordarse desde múltiples dimensiones:

- Factores Predictivos: Incluyen características demográficas, académicas, económicas y sociales de los estudiantes que pueden influir en su decisión de continuar o abandonar sus estudios (Nieuwoudt y Pedler, 2021).
- Intervenciones Institucionales: Estrategias desarrolladas por las instituciones para mejorar la retención, tales como tutorías, asesoramiento académico, apoyo financiero, y actividades de integración estudiantil.
- Medición del Éxito: Se evalúa mediante indicadores como tasas de retención año a año, tasas de graduación, y el tiempo promedio para completar los grados.
- Impacto de las Tecnologías: El uso de tecnologías como la inteligencia artificial para identificar estudiantes en riesgo de abandono escolar y para personalizar el aprendizaje y el apoyo académico.
- Perspectivas Teóricas: Enfoques teóricos que explican por qué los estudiantes deciden permanecer en la institución o abandonarla, como la teoría de la integración de Tinto (1987), que enfatiza la importancia de la integración académica y social de los estudiantes en su entorno universitario.

Es crucial reconocer las principales tendencias emergentes en IA y su aplicación en la educación superior, un campo que está experimentando una revolución debido a la capacidad de estas tecnologías de ofrecer soluciones personalizadas y adaptativas. Estas tecnologías no solo facilitan una gestión más eficiente de los recursos educativos, sino que también permiten identificar patrones de comportamiento estudiantil y predecir el riesgo de deserción, lo cual es clave para implementar estrategias proactivas de retención estudiantil (Saltos-García *et al.*, 2024).

La IA ha catalizado cambios significativos en la educación superior al posibilitar intervenciones más efectivas que abarcan desde la personalización del aprendizaje, mediante sistemas de tutorías inteligentes y plataformas adaptativas, hasta el uso de análisis predictivos que mejoran la eficiencia y el rendimiento estudiantil. Este avance se ha visto apoyado por un aumento en la disponibilidad de datos educativos y la mejora en los algoritmos, lo que ha permitido un entendimiento más profundo del proceso educativo y ha fortalecido la capacidad de anticipar y satisfacer las necesidades individuales de cada estudiante de manera efectiva (Dávila *et al.*, 2024).

2. Metodología

Esta investigación se ha realizado siguiendo el protocolo PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*), un marco estructurado y ampliamente reconocido para garantizar la consistencia y calidad en revisiones sistemáticas y metaanálisis. PRISMA ofrece un enfoque que asegura la transparencia y reproducibilidad de la investigación, proporcionando una lista de verificación y un diagrama de flujo que documentan cada paso del proceso, desde la selección de estudios hasta la síntesis de resultados (Moher *et al.*, 2009).

En la etapa inicial, se desarrolló un protocolo detallado que definió las preguntas de investigación y los criterios de inclusión y exclusión. Se seleccionaron estudios que examinaran el impacto de las aplicaciones de IA en la retención estudiantil en educación superior y se descartaron los que no cumplieran con los estándares de calidad o relevancia.

Se utilizaron los operadores booleanos y signos truncados para refinar la búsqueda, integrando términos relacionados con IA ("artificial intelligence", "machine learning", "data mining", "predictive analytics") y retención estudiantil ("student retention", "dropping out", "student persistence", "attrition", "dropout rate"), limitándolos a educación superior. La búsqueda se restringió a artículos publicados desde 2019, logrando una selección precisa y relevante de investigaciones sobre el impacto de la IA en la retención estudiantil.

Se realizaron búsquedas exhaustivas en bases de datos académicas interdisciplinarias como SCOPUS, Web of Science (WOS), y ERIC, una base de datos específica de educación. Los estudios seleccionados fueron sometidos a un proceso de análisis y revisión exhaustivo, incluyendo la eliminación de artículos duplicados presentes en diversas bases de datos.

En la primera fase de selección, se identificaron 320 artículos, de los cuales 69 estaban duplicados, resultando en 251 artículos para un análisis más detallado. En la fase de análisis primario, se evaluaron estos 251 artículos, excluyendo 185 por no estar relacionados con la aplicación de la IA en la retención estudiantil, dejando 66 artículos para el análisis secundario.

Durante el análisis secundario, se evaluaron rigurosamente los 66 artículos, excluyendo 18 que no respondían a las preguntas de investigación. Finalmente, 48 estudios fueron incluidos en la revisión sistemática.

Este análisis detallado permitió elaborar una revisión comprensiva de los artículos, sintetizando y discutiendo los hallazgos significativos sobre cómo las aplicaciones de IA están redefiniendo las estrategias de retención en la educación superior, y abordando los desafíos éticos y operativos asociados con la implementación de estas tecnologías (tabla 1).

Tabla 1.

Resultados de la selección de fuentes consultadas

Fase de Selección	Artículos Incluidos	Artículos Excluidos	Motivo de Exclusión
Inicial	320	69	Duplicados
Análisis Primario	251	185	Falta de adecuación al ámbito de estudio
Análisis Secundario	66	18	No responder a las preguntas de investigación
Selección Final	48	-	-

Fuente: Elaboración Propia.

Nota: Fase de Selección: Etapas del proceso PRISMA, desde la selección inicial hasta la final. Artículos Incluidos: Número de artículos que avanzaron tras cada filtro. Artículos Excluidos: Número de artículos excluidos y principales motivos. Motivo de Exclusión: Criterio principal de exclusión en cada fase.


3. Resultados

3.1. *¿Cómo ha evolucionado la investigación en torno a la IA y sus aplicaciones en el ámbito de investigación relacionado con el abandono y la retención educativa?*

La selección de artículos permitió observar la tendencia en la cantidad de publicaciones desde 2019 hasta 2024, destacando un aumento significativo en 2023 (Figura 1). El año 2022 también presentó un incremento notable, lo cual sugiere un creciente interés en la aplicación de la IA en el ámbito de la educación superior en relación con el diseño y desarrollo de estrategias para la retención estudiantil. Lo anterior, subraya la importancia y relevancia del tema de estudio, proporcionando un contexto pertinente para la discusión presentada en este documento.

Figura 1.

Crecimiento anual en el número de artículos publicados sobre IA en Educación Superior



Fuente: Elaboración Propia

Un dato importante que se aprecia en la Figura 1 es que la IA, aunque ha experimentado varios períodos de auge y declive desde su concepción está generando actualmente mucho interés en la comunidad científica. Los años 2022 y 2023 demuestran una tendencia al alza en este campo coincidiendo con momentos de grandes avances de la IA que han captado la atención tanto del sector tecnológico como del resto de sectores y del público general, consolidando aún más su impacto en diversas industrias.

En 2022, un evento destacado fue el lanzamiento y la adopción masiva de modelos de lenguaje de IA como ChatGPT de OpenAI, que logró democratizar el acceso a la tecnología de IA conversacional. Este tipo de modelos mostraron capacidades avanzadas en generar textos coherentes y contextuales, facilitando tareas desde la atención al estudiante hasta la creación de contenido, y demostrando la utilidad práctica del procesamiento de lenguaje natural a gran escala (Salas-Pilco y Yang 2022). Y en 2023, la tendencia ha continuado con mejoras en la eficiencia, la capacidad y la ética de los algoritmos de IA (Jongile y Ivala, 2023).

3.2. ¿De qué manera pueden las tecnologías de información y análisis de datos ser empleados para identificar y abordar los factores de riesgo de abandono en la educación superior antes de que comprometan el rendimiento académico de los estudiantes?

La revisión de los artículos seleccionados resalta cómo las tecnologías de información y análisis de datos, particularmente *Machine learning* (ML), *Learning analytics* (LA), IA, Redes Neuronales (NN) y *Big data* (BD), ofrecen métodos avanzados y eficaces para abordar proactivamente los desafíos asociados con el abandono escolar en la educación superior (Tabla 2). Estas tecnologías se implementan de diversas maneras para identificar patrones de riesgo y proporcionar soluciones personalizadas que mejoran la tasa de retención y el rendimiento estudiantil:

- a. **Predicción del Abandono:** Utilizando ML, LA, IA, NN, y BD, los educadores pueden desarrollar modelos predictivos que identifican estudiantes en riesgo de abandono antes de que su rendimiento académico decline. Por ejemplo, en el uso de ML, Tang *et al.* (2024) y Fahd *et al.* (2021) aplicaron técnicas de aprendizaje automático para evaluar y prever el riesgo de abandono. En el ámbito de LA, Jongile y Ivala (2023) desarrollaron modelos analíticos para detectar precozmente a estudiantes en riesgo. Delcker *et al.* (2024) y Singh *et al.* (2023) emplearon la inteligencia artificial para anticipar y reducir la deserción estudiantil, utilizando modelos predictivos que estiman cómo se utilizan las herramientas de IA en los procesos de aprendizaje. Utilizando NN, Alcauter *et al.* (2023) y Vidal *et al.* (2022) analizaron patrones de datos para identificar factores de riesgo de abandono. Finalmente, el uso de BD en los estudios de Gkontzis *et al.* (2019) y Matz *et al.* (2023) permitió predecir y entender mejor las dinámicas de la deserción.

- b. Estrategias de Retención: A través de ML, IA, NN, y BD, los educadores pueden implementar estrategias de retención efectivas que adaptan las intervenciones educativas a las necesidades individuales de los estudiantes. Utilizando ML, estudios como los de Okewu *et al.* (2021) y Cardona *et al.* (2020) desarrollaron modelos para analizar y predecir la retención estudiantil, facilitando así intervenciones personalizadas. En el campo de la IA, Delcker *et al.* (2024) y Singh *et al.* (2023) utilizaron IA para prever necesidades de apoyo y ajustar recursos educativos en tiempo real. Por su parte, Alcauter *et al.* (2023) y Vidal *et al.* (2022) aplicaron NN para modelar y entender profundamente los patrones de riesgo, permitiendo intervenciones más precisas. Finalmente, mediante el uso de BD, estudios como los de Gkontzis *et al.* (2019) y Matz *et al.* (2023) aprovecharon grandes conjuntos de datos para identificar tendencias y factores clave que afectan la retención estudiantil, lo que permitió una planificación más estratégica de los esfuerzos de retención.
- c. Mejora del Apoyo Educativo: A través de ML, LA, IA, NN, y BD, se pueden implementar sistemas avanzados que adaptan las intervenciones educativas a las necesidades individuales de los estudiantes, mejorando así su experiencia y rendimiento. Por ejemplo, en el uso de ML, Sihare (2024) y Hinojosa *et al.* (2022) identificaron patrones de comportamiento estudiantil para desarrollar intervenciones personalizadas. En el ámbito de LA, Ifenthaler y Yau (2020) analizaron datos de comportamiento para optimizar el apoyo estudiantil. La IA fue utilizada por Latif *et al.* (2022) y Nagy y Molontay (2023) para personalizar el contenido educativo y prever necesidades estudiantiles, mientras que, NN fueron aplicadas por Vidal *et al.* (2022) y Alcauter *et al.* (2023), para profundizar en el análisis de datos para ofrecer recomendaciones específicas. Finalmente, en el uso de BD, Gkontzis *et al.* (2019) entendieron los factores que afectan el rendimiento estudiantil, permitiendo una mejora sustancial en las estrategias de apoyo.

El uso predominante del ML e la IA en las tres áreas clave de la retención en educación superior –predicción del abandono, generación de estrategias de retención y mejora del apoyo educativo– puede atribuirse a varias razones fundamentales relacionadas con las capacidades y ventajas que ofrecen estas tecnologías; análisis y predicción; personalización y adaptabilidad; automatización y escalabilidad y mejora continua.

Así, el ML y la IA son ampliamente utilizadas en la educación superior por su capacidad para analizar grandes volúmenes de datos y personalizar intervenciones, lo que las hace esenciales para la predicción del abandono, la retención y el apoyo educativo. Tang *et al.* (2024) emplearon ML para desarrollar modelos predictivos que identifican estudiantes en riesgo, mientras que Fahd *et al.* (2021) utilizó técnicas de aprendizaje automático para evaluar y prever la atrición de los estudiantes a partir de una revisión meta-analítica de la literatura. La personalización de la educación, que es crucial para retener estudiantes y mejorar su experiencia educativa, se refleja esto en el trabajo de Delcker *et al.* (2024) y Singh *et al.* (2023), quienes aplicaron IA para adaptar los recursos educativos a las necesidades individuales de los estudiantes.

La capacidad de automatización y escalabilidad de ML e IA permite implementar soluciones extensibles en entornos educativos grandes, como lo sugiere la revisión de Okewu *et al.* (2021). Sihare (2024) aplicó ML para desarrollar sistemas automatizados que ayudan a predecir y gestionar el riesgo de abandono, proporcionando una base sólida para intervenciones escalables. Además, la capacidad de ML e IA para aprender de nuevos datos significa que los sistemas pueden mejorar continuamente su precisión y efectividad. Latif *et al.* (2022) exploraron cómo los modelos de IA se ajustan y evolucionan con cada nuevo conjunto de datos, mejorando la capacidad de predecir y retener a los estudiantes con éxito.

Tabla 2.

Resumen de Tecnologías de IA Aplicadas en Diversas Líneas de Estudio de Retención Estudiantil

Predicción del abandono: Estudios que utilizan tecnologías de IA para identificar tempranamente a los estudiantes con riesgo de abandono escolar.

Tecnología	Estudios Citados
ML: <i>Machine learning</i> (Aprendizaje Automático)	Gkontzis <i>et al.</i> (2019); Mubarak <i>et al.</i> (2020); Fomunyan (2020); Figueroa-Cañas y Sancho-Vinuesa (2020); Sani <i>et al.</i> (2020); Cardona <i>et al.</i> (2020); Shilbayeh y Abonamah (2021); Palacios <i>et al.</i> (2021); Ayouni <i>et al.</i> (2021); Fahd <i>et al.</i> (2021); Okewu <i>et al.</i> (2021); Albreiki (2022); Latif <i>et al.</i> (2022); Brdeseet <i>et al.</i> (2022); Salas-Pilco y Yang (2022); Coral <i>et al.</i> (2022); Zayed <i>et al.</i> (2022); Dake y Buabeng-Andoh (2022); Tang <i>et al.</i> (2023); Singh <i>et al.</i> (2023); Rodríguez <i>et al.</i> (2023); Fauszt <i>et al.</i> (2023); Colpo <i>et al.</i> (2023); Köhler y González-Ibáñez (2023); Nagy y Molontay (2023); Halat <i>et al.</i> (2023); Martins <i>et al.</i> (2023); Hoyos-Osorio y Santacoloma (2023); Crawford <i>et al.</i> (2023); Nasa-Ngium <i>et al.</i> (2023); Gutierrez-Pachas <i>et al.</i> (2023); Matz <i>et al.</i> (2023); Monteverde-Suárez <i>et al.</i> (2024); Okoye <i>et al.</i> (2024); Pêgo <i>et al.</i> (2024); Tang <i>et al.</i> (2024).
LA: <i>Learning analytics</i> (Analítica de Aprendizaje)	Fontana <i>et al.</i> (2021) ; Bulut <i>et al.</i> (2022); Jongile y Ivala (2023)
IA: Inteligencia Artificial	Latif <i>et al.</i> (2022) ; Salas-Pilco y Yang (2022) ; Singh <i>et al.</i> (2023) ; Nagy y Molontay (2023) ; Delcker <i>et al.</i> (2024)
NN: Neural Networks (Redes Neuronales)	Musso <i>et al.</i> (2020) ; Vidal <i>et al.</i> (2022) ; Alcauter <i>et al.</i> (2023)
BD: <i>Big data</i> (Datos Masivos)	Gkontzis <i>et al.</i> (2019) ; Matz <i>et al.</i> (2023)

Estrategias de retención: Estudios enfocados en el desarrollo y aplicación de estrategias de retención mediante el uso de IA.

Tecnología	Estudios Citados
ML: <i>Machine learning</i> (Aprendizaje Automático)	Gkontzis <i>et al.</i> (2019); Cardona <i>et al.</i> (2020); Mubarak <i>et al.</i> (2020); Ayouni <i>et al.</i> (2021); Palacios <i>et al.</i> (2021); Shilbayeh y Abonamah (2021); Okewu <i>et al.</i> (2021); Brdeseet <i>et al.</i> (2022); Dake y Buabeng-Andoh (2022); Hinojosa <i>et al.</i> (2022); Latif <i>et al.</i> (2022); Halat <i>et al.</i> (2023); Matz <i>et al.</i> (2023); Villegas-Ch <i>et al.</i> (2023); Fauszt <i>et al.</i> (2023); Sihare (2024); Okoye <i>et al.</i> (2024); Tang <i>et al.</i> (2024).
LA: <i>Learning analytics</i> (Analítica de Aprendizaje)	
IA: Inteligencia Artificial	Latif <i>et al.</i> (2022); Villegas-Ch <i>et al.</i> (2023); Delcker <i>et al.</i> (2024); Okoye <i>et al.</i> (2024); Sihare (2024).
NN: Neural Networks (Redes Neuronales)	Musso <i>et al.</i> (2020); Vidal <i>et al.</i> (2022); Alcauter <i>et al.</i> (2023).

BD: *Big data* (Datos Masivos) Gkontzis *et al.* (2019); Matz *et al.* (2023).

Mejora del Apoyo Educativo: Estudios que utilizan tecnologías de IA para mejorar el apoyo educativo y adaptar las intervenciones a las necesidades individuales de los estudiantes.

Tecnología	Estudios Citados
ML: <i>Machine learning</i> (Aprendizaje Automático)	Gkontzis <i>et al.</i> (2019); Cardona <i>et al.</i> (2020); Sani <i>et al.</i> (2020); Palacios <i>et al.</i> (2021); (Ayouni <i>et al.</i> , 2021); Latif <i>et al.</i> (2022); Hinojosa <i>et al.</i> (2022); Albreiki (2022); Dake y Buabeng-Andoh (2022); Zayed <i>et al.</i> (2022); Tang <i>et al.</i> (2023); Singh <i>et al.</i> (2023); Rodríguez <i>et al.</i> (2023); Colpo <i>et al.</i> (2023); Gutierrez-Pachas <i>et al.</i> (2023); Crawford <i>et al.</i> (2023); Martins <i>et al.</i> (2023); Christou <i>et al.</i> (2023); Nagy y Molontay (2023); Villegas-Ch <i>et al.</i> (2023); Halat <i>et al.</i> (2023); Tang <i>et al.</i> (2024); Sihare (2024); Pêgo <i>et al.</i> (2024).
LA: <i>Learning analytics</i> (Analítica de Aprendizaje)	Ifenthaler y Yau (2020); Bulut <i>et al.</i> (2022); Jongile y Ivala (2023).
IA: Inteligencia Artificial	Latif <i>et al.</i> (2022); Singh <i>et al.</i> (2023); Villegas-Ch <i>et al.</i> (2023); Nagy y Molontay (2023); Delcker <i>et al.</i> (2024); Sihare (2024).
NN: Neural Networks (Redes Neuronales)	Vidal <i>et al.</i> (2022); Alcauter <i>et al.</i> (2023).
BD: <i>Big data</i> (Datos Masivos)	Gkontzis <i>et al.</i> (2019).

Fuente: Elaboración Propia.

3.3. ¿Cuáles son los desafíos éticos y operativos más significativos que enfrenta la implementación de la Inteligencia Artificial en la retención estudiantil, especialmente en entornos de educación superior?

En relación con los desafíos éticos, uno de los aspectos a considerar es la privacidad y seguridad de los datos. La implementación de IA en educación superior requiere manejar grandes volúmenes de datos personales y sensibles de los estudiantes, lo que plantea preocupaciones significativas sobre la privacidad y la seguridad. Es fundamental que las instituciones establezcan protocolos rigurosos para la protección de datos para evitar brechas de seguridad que puedan comprometer la privacidad estudiantil. En la literatura revisada no se evidenciaron estudios específicos que aborden directamente estos aspectos éticos. Sin embargo, cualquier implementación de IA que involucre datos estudiantiles, como los modelos predictivos de Fahd *et al.* (2021), debe adherirse a políticas de privacidad y seguridad de datos.

Otro desafío ético importante es el sesgo y la justicia. La IA puede perpetuar o incluso incrementar los sesgos existentes si los datos utilizados para entrenar los modelos no son representativos o si los algoritmos no son diseñados con cuidado. Esto puede llevar a decisiones injustas o discriminación contra ciertos grupos de estudiantes. Latif *et al.* (2022) y Villegas-Ch *et al.* (2023) resaltaron la necesidad de aplicar la IA de manera ética y equitativa, asegurando que todas las intervenciones basadas en IA beneficien a todos los estudiantes, independientemente de su origen institucional o socioeconómico.

Respecto a los desafíos operativos, la integración de sistemas es uno de los primeros obstáculos. Integrar soluciones de IA en los sistemas existentes de las instituciones educativas puede ser complejo y costoso. Los desafíos incluyen la compatibilidad tecnológica, la necesidad de infraestructura adecuada y la capacitación del personal para utilizar estas nuevas herramientas eficazmente. La investigación de Delcker *et al.* (2024) ilustró cómo la competencia en IA de los estudiantes influye en el uso de herramientas de IA, subrayando la importancia de una integración sistemática que también incluya formación y apoyo.

La escalabilidad y el mantenimiento son retos operativos que también deben tenerse en cuenta. Mantener y escalar sistemas de IA para que sean efectivos en entornos educativos diversos y cambiantes es complejo. Esto requiere recursos continuos, actualizaciones tecnológicas y ajustes basados en retroalimentación y resultados de aprendizaje. Gkontzis *et al.* (2019) utilizaron BD para analizar la deserción estudiantil, siendo clave que sus sistemas puedan adaptarse y escalar conforme cambian las condiciones educativas y demográficas.

Finalmente, la transparencia y aplicabilidad son aspectos relevantes. Es necesario asegurar que las decisiones tomadas por sistemas de IA sean transparentes y explicables, para ganar la confianza de los estudiantes y el personal. La falta de transparencia en cómo la IA toma decisiones puede llevar a la resistencia y a preocupaciones éticas adicionales. Estudios como el de Nagy y Molontay (2023), que se enfocaron en la interpretación de las predicciones de IA, destacaron la necesidad de desarrollar modelos que no solo sean precisos sino también comprensibles para los usuarios no técnicos.

4. Discusión

La implementación de la IA en la educación superior está transformando el enfoque de las instituciones hacia la retención estudiantil, ofreciendo oportunidades notables para mejorar la predicción y gestión de la persistencia estudiantil, además de personalizar la experiencia educativa. El análisis de la percepción de los estudiantes sobre los servicios proporcionados y la orientación hacia enfoques educativos más inclusivos y personalizados han sido identificados como desafíos clave en investigaciones previas (Guzmán *et al.*, 2022; Segovia-García *et al.*, 2022) y están siendo abordados actualmente mediante la adopción de tecnologías avanzadas, como evidencian Hinojosa *et al.* (2022) y Singh *et al.* (2023). Estos estudios destacaron cómo la IA no solo mejora la personalización y la inclusividad de los servicios educativos, sino que también optimiza la respuesta institucional a las necesidades individuales de los estudiantes.

Uno de los temas centrales abordados por la comunidad científica en los estudios recientes es la utilización del BD y las técnicas de aprendizaje automático como estrategias fundamentales para combatir la deserción en la educación virtual. Este problema ha sido amplificado por la pandemia del COVID-19 y la masificación de la educación virtual, lo que ha representado un reto creciente para numerosas instituciones educativas (Colpo *et al.*, 2023). La coincidencia de este desafío con avances significativos en la investigación subraya la importancia de adaptarse e innovar en periodos críticos para mejorar la retención estudiantil.

Tomando como referencia las conclusiones más significativas de los estudios analizados se puede extrapolar cómo estas herramientas de IA ofrecen una experiencia educativa más adaptativa y personalizada, elevando considerablemente el compromiso y el éxito académico de los estudiantes. Algunos estudios que destacan estos aspectos son los de Salas-Pilco y Yang (2022) y Singh *et al.* (2023) que señalaron mejoras en los procesos de aprendizaje, enseñanza y administración. Nagy y Molontay (2023) demostró como son herramientas particularmente valiosas para personalizar intervenciones o Tang *et al.* (2024) y Rodríguez *et al.* (2023) que analizaron cómo las técnicas de aprendizaje automático pueden optimizar las medidas de apoyo académico al mejorar la predicción y gestión de la persistencia estudiantil.

La mayoría de los estudios contemplados señalan, un avance sustancial hacia un paradigma educativo altamente personalizado, orientado a satisfacer las necesidades particulares de cada estudiante y comprometido con los principios de igualdad y equidad. En este sentido Fomunyan (2020) sostiene que la IA tiene el potencial de adaptar la educación a estudiantes con requerimientos variados, ofreciendo así la oportunidad de atenuar las disparidades educativas en lugar de agravarlas. Además, la IA potencia la eficiencia en la administración de recursos y optimiza la toma de decisiones educativas, lo que contribuye a elevar la reputación de las instituciones al mejorar indicadores de retención y éxito estudiantil tal como señalan Okewu *et al.* (2021) quienes advirtieron cómo las NN y el análisis de datos educativos pueden emplearse para un asesoramiento académico fundamentado y un aprendizaje adaptativo, fomentando la retención y el avance académico de los estudiantes. Este estudio destaca la capacidad de la IA para revolucionar los procesos administrativos y académicos, incrementando la eficacia institucional y la reputación coincidiendo con lo trabajado por Salas-Pilco y Yang (2022).

Siguiendo con los beneficios de estas tecnologías emergentes y desde una perspectiva más funcional, Delcker *et al.* (2024) resaltó el potencial de herramientas de IA generativa, como los traductores, parafraseadores y, más recientemente, *chatbots*. Estas tecnologías pueden desempeñar un papel crucial en el apoyo a los estudiantes en sus procesos de aprendizaje, contribuyendo así al éxito académico. De manera complementaria, Albreiki (2022) presentó un caso específico donde modelos de IA se utilizan para diseñar acciones correctivas destinadas a asistir a estudiantes en riesgo, mejorando de este modo la retención y los resultados educativos. Este conjunto de estudios demuestra el considerable potencial de la IA para transformar el panorama educativo, enfatizando la importancia de implementar aplicaciones éticas y equitativas que beneficien a todos los estudiantes, sin importar su contexto socioeconómico o institucional.

Pese a las ventajas identificadas con el uso de la tecnología de IA, esta perspectiva no está exenta de críticas por parte de la comunidad científica. Se advierte que, en el contexto de la IA aplicada a la educación, los sesgos algorítmicos representan un desafío considerable. Ferrante (2021) enfatizó cómo estos sesgos pueden erosionar la confianza en las herramientas de IA y restringir su capacidad para proporcionar beneficios de manera equitativa a todos los estudiantes. Además, existe una preocupación concreta acerca del riesgo de que la IA profundice las desigualdades entre diferentes instituciones educativas, exacerbando la brecha entre instituciones, en términos de recursos financieros, y perpetuando sistemas educativos estratificados. En este escenario, Latif *et al.* (2022) y Villegas-Ch *et al.* (2023) destacaron la urgencia de implementar la IA de forma ética y equitativa, asegurando que las intervenciones tecnológicas beneficien a todos los estudiantes, sin distinción de su origen institucional o socioeconómico.

Junto con lo anterior, es importante destacar que la incorporación de tecnologías basadas en IA también trae consigo desafíos significativos, que incluyen altos costos de implementación y mantenimiento, y que representan barreras críticas, tal como se discute en los estudios de Okoye *et al.* (2024). Estos modelos avanzados de IA, aunque prometedores por su eficacia en mejorar los resultados educativos y operativos, demandan una infraestructura tecnológica robusta y un soporte técnico continuo para su gestión y actualización. Además, la adopción de estas tecnologías implica desafíos en cuanto a la privacidad de los datos y la seguridad, lo que requiere que las instituciones educativas establezcan protocolos estrictos y cumplan con normativas específicas para proteger la información sensible de los estudiantes.

En este contexto, se abren diversas líneas de investigación que buscan complementar el trabajo realizado por Segovia-García y Martín-Caro (2023), centradas en evaluar el impacto económico de estas nuevas herramientas tecnológicas en la estructura de costos institucionales. Estos estudios son cruciales, ya que, en todas las modalidades educativas, incluida la virtual, se observa que las actividades relacionadas con el diseño instruccional y la docencia representan la mayor parte de los costos. Sin embargo, la adopción de modelos de inteligencia artificial no solo implica una inversión económica significativa, sino que también requiere de capacidades técnicas avanzadas y de recursos humanos altamente especializados.

Finalmente, para maximizar los beneficios y minimizar los riesgos asociados con la IA en la educación, es esencial que las instituciones inviertan en programas de formación continua que no solo capaciten al personal en las competencias técnicas necesarias, sino que también fomenten una comprensión crítica de las implicancias éticas de la inteligencia artificial. Este enfoque integral ayudará a asegurar que la tecnología se utilice de manera que respete los principios de equidad y justicia, y contribuya efectivamente al progreso educativo de todos los estudiantes, independientemente de su trasfondo socioeconómico.

5. Conclusiones

Este estudio exploró el impacto de la IA en la educación superior, centrándose particularmente en la retención estudiantil. La implementación de IA se demuestra como una herramienta crucial para mejorar la predicción y gestión de la persistencia estudiantil, personalizando la experiencia educativa para fomentar un mayor compromiso y éxito académico.

Desde una perspectiva institucional, la IA mejora la eficiencia en la gestión de recursos y optimiza la toma de decisiones educativas. Esto no solo tiene un impacto sobre la reputación institucional, sino que también fortalece los resultados en retención y éxito estudiantil. Sin embargo, la adopción de estas tecnologías no está exenta de desafíos. Los altos costos de implementación y mantenimiento, junto con la necesidad de formación avanzada y la superación de barreras técnicas, representan obstáculos significativos que deben abordarse para maximizar los beneficios de la IA.

En términos éticos, es imperativo que la implementación de IA se maneje con una consideración rigurosa hacia la equidad y la inclusión, asegurando que todos los estudiantes, independientemente de su origen institucional o socioeconómico, se beneficien de manera justa de estas intervenciones.

Las instituciones deberían considerar inversiones estratégicas en IA, no solo desde el punto de vista tecnológico sino también en capacitación y desarrollo profesional para educadores y administrativos. Es necesario desarrollar un marco ético robusto que guíe la implementación de IA, enfocado en proteger la privacidad de los datos estudiantiles y que asegure que los algoritmos estén libres de sesgos. Es importante priorizar la inclusión y la accesibilidad en el diseño de herramientas de IA para garantizar que todas las intervenciones sean equitativas y beneficien a toda la diversidad estudiantil.

Las futuras investigaciones podrían explorar más profundamente los impactos a largo plazo de la IA en diferentes contextos educativos, incluyendo la educación a distancia y los entornos híbridos. Además, estudios adicionales se pueden centrar en el desarrollo de modelos de IA más explicables y transparentes que puedan ser fácilmente interpretados por los no especialistas, mejorando así la confianza y la adopción de estas tecnologías.

Las investigaciones futuras en el desarrollo de la inteligencia artificial (IA) pueden beneficiarse de un enfoque interdisciplinario que incorpore disciplinas como la psicología educativa, la ingeniería de datos y la ética, lo que permitiría crear modelos de IA más adaptados a las necesidades humanas y contextuales. Asimismo, es fundamental evaluar el impacto socioeconómico de la IA en la educación para entender cómo estas tecnologías afectan la equidad educativa globalmente, identificando tanto los beneficios como los riesgos de profundizar las disparidades educativas entre distintas regiones y poblaciones. Además, se debe investigar cómo optimizar la IA para la personalización masiva, de manera que las soluciones puedan escalar para atender a grandes poblaciones estudiantiles sin perder calidad ni precisión. Con el avance tecnológico, también aumenta la necesidad de proteger los datos sensibles de los estudiantes; por lo tanto, es crucial desarrollar nuevas estrategias y tecnologías que aseguren la privacidad y la seguridad de los datos frente a vulnerabilidades emergentes. Finalmente, ante la creciente integración de la IA en la educación, se hace imprescindible desarrollar políticas y marcos regulatorios robustos que promuevan la innovación mientras protegen a los estudiantes y garantizan prácticas éticas y justas.

El estudio actual aporta al conocimiento en el campo de la IA en la educación superior y establece una base sólida para la continuación del diálogo y la investigación en esta área emergente y críticamente importante.

6. Referencias

- Albreiki, B. (2022). Framework for automatically suggesting remedial actions to help students at risk based on explainable ML and rule-based models. *International Journal Of Educational Technology In Higher Education*, 19(1). <https://acortar.link/u9ENJZ>
- Alcauter, I., Martínez-Villaseñor, L. y Pönce, H. (2023). Explaining Factors of Student Attrition at Higher Education. *Computación y Sistemas*, 27(4). <https://acortar.link/FQJPLX>
- Ayouni, S., Hajjej, F., Maddeh, M. y Al-Otaibi, S. (2021). A new ML-based approach to enhance student engagement in online environment. *PloS One*, 16(11), e0258788. <https://doi.org/10.1371/journal.pone.0258788>
- Brdese, H., Alsaggaf, W., Aljohani, N. R. y Hassan, S. (2022). Predictive Model Using a Machine learning Approach for Enhancing the Retention Rate of Students At-Risk. *International Journal On Semantic Web And Information Systems*, 18(1), 1-21. <https://doi.org/10.4018/ijswis.299859>

- Bulut, O., Gorgun, G., Yildirim-Erbasli, S. N., Wongvorachan, T., Daniels, L. M., Gao, Y., Lai, K. W. y Shin, J. (2022). Standing on the shoulders of giants: Online formative assessments as the foundation for predictive learning analytics models. *British Journal Of Educational Technology*, 54(1), 19-39. <https://doi.org/10.1111/bjet.13276>
- Cardona, T., Cudney, E. A., Hoerl, R. W. y Snyder, J. L. (2020). Data Mining and Machine learning Retention Models in Higher Education. *Journal Of College Student Retention*, 25(1), 51-75. <https://doi.org/10.1177/1521025120964920>
- Christou, V., Tsoulos, I. G., Loupas, V., Tzallas, A. T., Gogos, C., Karvelis, P., Antoniadis, N., Glavas, E. y Γιαννικάκης, Ν. (2023). Performance and early drop prediction for higher education students using machine learning. *Expert Systems With Applications*, 225, 120079. <https://doi.org/10.1016/j.eswa.2023.120079>
- Colpo, M. P., Primo, T. T. y De Aguiar, M. S. (2023). Lessons learned from the student dropout patterns on COVID-19 pandemic: An analysis supported by machine learning. *British Journal Of Educational Technology*, 55(2), 560-585. <https://doi.org/10.1111/bjet.13380>
- Coral, M. Á. V., Salazar-Ramírez, L., Injante, R., Hernandez-Torres, E. A., Díaz, J. R. J., Navarro-Cabrera, J. R., Pinedo, L. y Vidaurre-Rojas, P. (2022). Density-Based Unsupervised Learning Algorithm to Categorize College Students into Dropout Risk Levels. *Data*, 7(11), 165. <https://doi.org/10.3390/data7110165>
- Crawford, J., Allen, K., Sanders, T., Baumeister, R. F., Parker, P. D., Saunders, C. y Tice, D. M. (2023). Sense of belonging in higher education students: an Australian longitudinal study from 2013 to 2019. *Studies In Higher Education*, 49(3), 395-409. <https://doi.org/10.1080/03075079.2023.2238006>
- Dake, D. K. y Buabeng-Andoh, C. (2022). Using Machine learning Techniques to Predict Learner Drop-out Rate in Higher Educational Institutions. *Journal Of Mobile Information Systems*, 1-9. <https://doi.org/10.1155/2022/2670562>
- Dávila, M. F. G., Cofre, I. J. M., Rosero, F. V. G. y Noroña, J. H. J. (2024). Inteligencia Artificial: Ventajas y desventajas de su uso en el proceso de enseñanza aprendizaje. *MENTOR Revista de Investigación Educativa y Deportiva*, 3(7), 202-224. <https://doi.org/10.56200/mried.v3i7.7081>
- Delcker, J., Heil, J., Ifenthaler, D., Seufert, S. y Spirgi, L. (2024). First-year students AI-competence as a predictor for intended and de facto use of AI-tools for supporting learning processes in higher education. *International Journal Of Educational Technology In Higher Education*, 21(1). <https://doi.org/10.1186/s41239-024-00452-7>
- Fahd, K., Venkatraman, S., Miah, S. J. y Ahmed, K. (2021). Application of machine learning in higher education to assess student academic performance, at-risk, and attrition: A meta-analysis of literature. *Education And Information Technologies*, 27(3), 3743-3775. <https://doi.org/10.1007/s10639-021-10741-7>
- Fauszt, T., Erdélyi, K., Dobák, D., Bognár, L. y Endre, K. (2023). Design of a Machine learning Model to Predict Student Attrition. *International Journal Of Emerging Technologies In Learning/International Journal: Emerging Technologies In Learning*, 18(17), 184-195. <https://doi.org/10.3991/ijet.v18i17.41449>

- Ferrante E. (2021). *Inteligencia artificial y sesgos algorítmicos. ¿Por qué deberían importarnos?* https://static.nuso.org/media/articles/downloads/1.TC_Ferrante_294.pdf
- Figueroa-Cañas, J. y Sancho-Vinuesa, T. (2020). Early Prediction of Dropout and Final Exam Performance in an Online Statistics Course. *IEEE-RITA*, 15(2), 86-94. <https://doi.org/10.1109/rita.2020.2987727>
- Fomunyan, K. G. (2020). Theorising Machine learning as an Alternative Pathway for Higher Education in Africa. *International Journal Of Education And Practice*, 8(2), 268-277. <https://doi.org/10.18488/journal.61.2020.82.268.277>
- Fontana, L., Masci, C., Ieva, F. y Paganoni, A. M. (2021). Performing Learning analytics via Generalised Mixed-Effects Trees. *Data*, 6(7), 74. <https://doi.org/10.3390/data6070074>
- Gkontzidis, A. F., Kotsiantis, S., Panagiotakopoulos, C. y Verykios, V. S. (2019). A predictive analytics framework as a countermeasure for attrition of students. *Interactive Learning Environments*, 30(6), 1028-1043. <https://doi.org/10.1080/10494820.2019.1709209>
- Gutierrez-Pachas, D. A., Garcia-Zanabria, G., Cuadros-Vargas, E., Cámara-Chávez, G. y Gómez-Nieto, E. (2023). Supporting Decision-Making Process on Higher Education Dropout by Analyzing Academic, Socioeconomic, and Equity Factors through Machine learning and Survival Analysis Methods in the Latin American Context. *Education Sciences*, 13(2), 154. <https://doi.org/10.3390/educsci13020154>
- Guzmán, A., Moreno, S. B., Cala-Vitery, F. y Segovia-García, N. (2022). Deserción en la Educación Superior Rural: Análisis de Causas desde el Pensamiento Sistémico. *Qualitative Research In Education*, 11(2), 118-150. <https://doi.org/10.17583/qre.10048>
- Halat, D. H., Abdel-Salam, A. G., Said, A. B., Soltani, A., Alsarraj, L., Dalli, R. y Malki, A. (2023). Use of *machine learning* to assess factors affecting progression, retention, and graduation in first-year health professions students in Qatar: a longitudinal study. *BMC Medical Education*, 23(1). <https://doi.org/10.1186/s12909-023-04887-w>
- Hinojosa, M., Dérpich, I., Alfaro, M., Ruete, D., Caroca, A. y Gatica, G. (2022). Procedimiento de agrupación de estudiantes según riesgo de abandono para mejorar la gestión estudiantil en educación superior. *Texto Livre*, 15, e37275. <https://doi.org/10.35699/1983-3652.2022.37275>
- Hoyos-Osorio, K. y Santacoloma, G. D. (2023). Predictive Model to Identify College Students with High Dropout Rates. *Revista Electrónica de Investigación Educativa*, 25, 1-10. <https://doi.org/10.24320/redie.2023.25.e13.5398>
- Ifenthaler, D. y Yau, J. Y. (2020). Utilising learning analytics to support study success in higher education: a systematic review. *Educational Technology Research And Development*, 68(4), 1961-1990. <https://doi.org/10.1007/s11423-020-09788-z>
- Jongile, S. y Ivala, E. (2023). A Theory-Driven Learning Analytic Model for Detecting Students at Risk in Higher Education. *Ubiquitous Learning*, 17(2), 1-17. <https://doi.org/10.18848/1835-9795/cgp/v17i02/1-17>
- Köhler, J., y González-Ibáñez, R. (2023). Information Competences and Academic Achievement: A Dataset. *Data*, 8(11), 164. <https://doi.org/10.3390/data8110164>

- Latif, G., Alghazo, R., Pilotti, M. y Brahim, G. B. (2022). Identifying «At-Risk» students: An AI-based prediction approach. *International Journal Of Computing And Digital System*, 11(1), 1051-1059. <https://doi.org/10.12785/ijcds/110184>
- Martins, M. V., Baptista, L., Machado, J. y Realinho, V. (2023). Multi-Class Phased Prediction of Academic Performance and Dropout in Higher Education. *Applied Sciences*, 13(8), 4702. <https://doi.org/10.3390/app13084702>
- Matz, S., Bukow, C. S., Peters, H., Deacons, C. y Stachl, C. (2023). Using machine learning to predict student retention from socio-demographic characteristics and app-based engagement metrics. *Scientific Reports*, 13(1). <https://acortar.link/OtN2Mj>
- Moher, D., Liberati, A., Tetzlaff, J. y Altman, D. G. (2009). Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement. *PLoS Medicine*, 6(7), e1000097. <https://doi.org/10.1371/journal.pmed.1000097>
- Monteverde-Suárez, D., González-Flores, P., Santos-Solórzano, R., García-Minjares, M., Zavala-Sierra, I. R., De la Luz, V. L. y Sánchez-Mendiola, M. (2024). Predicting students' academic progress and related attributes in first-year medical students: an analysis with artificial neural networks and Naïve Bayes. *BMC Medical Education*, 24(1). <https://doi.org/10.1186/s12909-023-04918-6>
- Mubarak, A. A., Cao, H. y Zhang, W. (2020). Prediction of students' early dropout based on their interaction logs in online learning environment. *Interactive Learning Environments*, 30(8), 1414-1433. <https://doi.org/10.1080/10494820.2020.1727529>
- Musso, M., Hernández, C. F. R. y Cascallar, E. (2020). Predicting key educational outcomes in academic trajectories: a machine-learning approach. *Higher Education*, 80(5), 875-894. <https://doi.org/10.1007/s10734-020-00520-7>
- Nagy, M. y Molontay, R. (2023). Interpretable dropout prediction: towards XAI-Based Personalized intervention. *International Journal Of Artificial Intelligence In Education*. <https://doi.org/10.1007/s40593-023-00331-8>
- Nasa-Ngium, P., Nuankaew, W., Phanniphong, K., Jeefoo, P., y Nuankaew, P. (2023). Predictive Models for Dropout Rates Affected by COVID-19 Using Classification and Feature Selection Techniques. *International Journal Of Engineering Trends And Technology*, 71(7), 349-356. <https://doi.org/10.14445/22315381/ijett-v71i7p233>
- Nieuwoudt, J. E. y Pedler, M. L. (2021). Student retention in higher education: Why students choose to remain at university. *Journal of Student Affairs Research and Practice*, 25(2). <https://doi.org/10.1177/1521025120985228>
- Okewu, E., Adewole, P., Misra, S., Maskeliūnas, R. y Damaševičius, R. (2021). Artificial Neural Networks for Educational Data Mining in Higher Education: A Systematic Literature Review. *Applied Artificial Intelligence*, 35(13), 983-1021. <https://doi.org/10.1080/08839514.2021.1922847>
- Okoye, K., Nganji, J. T., Escamilla, J. y Hosseini, S. (2024). Machine learning model (RG-DMML) and ensemble algorithm for prediction of students' retention and graduation in education. *Computers And Education. Artificial Intelligence*, 6, 100205. <https://doi.org/10.1016/j.caeai.2024.100205>

- Orellana, D., Segovia-García, N. y Cánovas, B. R. (2020). El abandono estudiantil en programas de educación superior virtual: revisión de literatura. *Revista de la Educación Superior*, 49(194), 45-62. <https://doi.org/10.36857/resu.2020.194.1124>
- Palacios, C. A., Reyes-Suárez, J. A., Bearzotti, L., Leiva, V. y Marchant, C. (2021). Knowledge Discovery for Higher Education Student Retention Based on Data Mining: Machine learning Algorithms and Case Study in Chile. *Entropy*, 23(4), 485. <https://doi.org/10.3390/e23040485>
- Pêgo, J. P., Miguéis, V. L. y Soeiro, A. (2024). Students' complex trajectories: exploring degree change and time to degree. *International Journal Of Educational Technology In Higher Education*, 21(1). <https://doi.org/10.1186/s41239-024-00438-5>
- Quecano, L. I. V., Rincón, A. G. y Moreno, S. B. (2024). Dropout in postgraduate programs: a underexplored phenomenon – a scoping review. *Cogent Education*, 11(1). <https://doi.org/10.1080/2331186x.2024.2326705>
- Rodríguez, P., Villanueva, A., Dombrowskaia, L. y Valenzuela, J. P. (2023). A methodology to design, develop, and evaluate *machine learning* models for predicting dropout in school systems: the case of Chile. *Education And Information Technologies*, 28(8), 10103-10149. <https://doi.org/10.1007/s10639-022-11515-5>
- Salam, M. y Farooq, M.S. (2020). Does sociability quality of web-based collaborative learning information system influence students' satisfaction and system usage? *International Journal of Educational Technology in Higher Education*, 17(1), 1-39. <https://doi.org/10.1186/s41239-020-00189-z>
- Salas-Pilco, S. Z. y Yang, Y. (2022). Artificial intelligence applications in Latin American higher education: a systematic review. *International Journal Of Educational Technology In Higher Education*, 19(1). <https://doi.org/10.1186/s41239-022-00326-w>
- Saltos-García, P. A., Zambrano-Loja, C. M., Rodríguez-Carló, D. F. y Cobeña-Talledo, R. A. (2024). Análisis del impacto de las estrategias de seguimiento académico basados en la inteligencia artificial en el rendimiento de estudiantes universitarios en programas de administración. *MQRInvestigar*, 8(2), 1930-1949. <https://doi.org/10.56048/mqr20225.8.2.2024.1930-1949>
- Sani, N. S., Nafuri, A. F. M., Othman, Z. A., Nazri, M. Z. A. y Mohamad, K. N. (2020). Drop-Out Prediction in Higher Education Among B40 Students. *International Journal Of Advanced Computer Science And Applications*, 11(11). <https://doi.org/10.14569/ijacsa.2020.0111169>
- Segovia-García, N. (2022). Educación superior online. *Human Review*, 11(Monográfico), 1-13. <https://doi.org/10.37467/revhuman.v11.3971>
- Segovia-García, N. y Said-Hung, E.M. (2021). Factores de satisfacción de los alumnos en e-learning en Colombia. *Revista Mexicana de Investigación Educativa*, 26(89), 595-621. <https://cutt.ly/LbUPghi>
- Segovia-García, N. y Martín-Caro, E. (2023). Cost Analysis in Online Teaching Using an Activity Map. *Education Sciences*, 13(5), 506. <https://doi.org/10.3390/educsci13050506>

- Segovia-García, N., Said-Hung, E. y Aguilera, F. J. G. (2022). Educación superior virtual en Colombia: factores asociados al abandono. *Educación XX1*, 25(1), 197-218. <https://doi.org/10.5944/educxx1.30455>
- Shilbayeh, S. y Abonamah, A. A. (2021). Predicting Student Enrolments and Attrition Patterns in Higher Educational Institutions using Machine learning. *The International Arab Journal Of Information Technology*, 18(4). <https://doi.org/10.34028/18/4/8>
- Sihare, S. R. (2024). Student Dropout Analysis in Higher Education and Retention by Artificial Intelligence and Machine learning. *SN Computer Science*, 5(2). <https://doi.org/10.1007/s42979-023-02458-w>
- Singh, H., Kaur, B., Sharma, A. y Singh, A. (2023). Framework for suggesting corrective actions to help students intended at risk of low performance based on experimental study of college students using explainable machine learning model. *Education And Information Technologies*. <https://doi.org/10.1007/s10639-023-12072-1>
- Tinto, V. (1987). *Leaving College: Rethinking the Causes and Cures of Student Attrition*. University Of Chicago Press.
- Tang, Z., Chen, L. y Jain, A. (2023). Exploring Individual Feature Importance in Student Persistence Prediction. *Journal Of Higher Education Theory And Practice*, 23(6). <https://doi.org/10.33423/jhetp.v23i6.5957>
- Tang, Z., Jain, A. y Colina, F. E. (2024). A Comparative Study of Machine learning Techniques for College Student Success Prediction. *Journal Of Higher Education Theory And Practice*, 24(1). <https://doi.org/10.33423/jhetp.v24i1.6764>
- Vidal, J., Corbí, R. G., Pozo-Rico, T., Costa, J. L. C. y Sánchez, T. (2022). Predictors of University Attrition: Looking for an Equitable and Sustainable Higher Education. *Sustainability*, 14(17), 10994. <https://doi.org/10.3390/su141710994>
- Villegas-Ch, W., Govea, J. y Revelo-Tapia, S. (2023). Improving Student Retention in Institutions of Higher Education through *Machine learning*: A Sustainable Approach. *Sustainability*, 15(19), 14512. <https://doi.org/10.3390/su151914512>
- Zayed, Y., Salman, Y. y Hasasneh, A. (2022). A Recommendation System for Selecting the Appropriate Undergraduate Program at Higher Education Institutions Using Graduate Student Data. *Applied Sciences*, 12(24), 12525. <https://doi.org/10.3390/app122412525>

CONTRIBUCIONES DE AUTORES/AS, FINANCIACIÓN Y AGRADECIMIENTOS

Financiación: Esta investigación no recibió financiamiento externo.

Agradecimientos: El presente texto nace en el marco de las actividades del Doctorado en Ciencias de la Educación de la Universidad Europea de Monterrey.

AUTOR/ES:**Ester Martín-Caro**

Universidad Europea de Monterrey y Corporación Universitaria de Asturias.

Doctora en Ciencias Económicas y Empresariales con la Tesis Doctoral titulada “El proceso de integración de los Mercados de Valores: Un Método de Valoración de los Costes de Contratación”. Posee un MBA de IESE Business School, Universidad de Navarra. Desde su incorporación a la Vicerrectoría Académica de la Corporación Universitaria de Asturias, ha publicado varios artículos sobre Educación Superior Online.

emartincaro@iep.edu.es**Orcid ID:** <https://orcid.org/0000-0002-7674-3068>**Google Scholar:** <https://scholar.google.com.mx/citations?hl=es&user=UV2Fh-AAAAAJ>