

Artículo de revisión

Factores de deserción estudiantil y estrategias de retención en carreras universitarias de Ingeniería y Áreas Técnicas

Humphrey Xavier Rubio-Tobar ^[1] 

[1] Universidad de Investigación e Innovación de México (UIIX). Escuela de Doctorado. Morelos, México.

Autor para correspondencia: hrubiot@comunidad.uiix.edu.mx



Resumen

La deserción estudiantil en la educación superior, particularmente en carreras de ingeniería y áreas técnicas, tiene implicaciones académicas, sociales y económicas ampliamente documentadas. Este estudio presenta una Revisión Sistemática de Literatura (SLR) basada en 57 artículos publicados entre 2000 y 2024 en la base de datos Scopus. A partir de la revisión, se evidenciaron factores relacionados con el abandono estudiantil y estrategias reportadas para mejorar la retención. Los hallazgos se agruparon en clústeres temáticos que destacan el uso de tecnologías de aprendizaje automático para predecir el riesgo académico, la influencia de factores socioeconómicos y psicosociales en la deserción, y la efectividad de políticas institucionales orientadas a la retención. La literatura señala que variables como el desempeño académico previo, la autoeficacia y el acceso a recursos económicos son predictores clave del abandono. Herramientas de analítica educativa, como algoritmos de aprendizaje profundo, han mostrado alta precisión en la identificación temprana de estudiantes en riesgo, aunque su implementación enfrenta limitaciones en contextos rurales o con infraestructura tecnológica insuficiente. Este análisis enfatiza la importancia de estrategias integrales que combinen enfoques tecnológicos, pedagógicos y psicosociales. Si bien las tecnologías avanzadas ofrecen ventajas notables, su efectividad y sostenibilidad dependen de su adaptabilidad a diferentes contextos y de la incorporación de factores humanos en los modelos predictivos.

Palabras Clave: *deserción estudiantil, retención académica, educación superior, ingeniería, aprendizaje automático.*

Student Dropout Factors and Retention Strategies in Engineering and Technical University Degrees

Abstract

Student dropout in higher education, particularly in engineering and technical fields, entails well-documented academic, social, and economic implications. This study presents a Systematic Literature Review (SLR) based on 57 articles published between 2000 and 2024 from the Scopus database. The review identified factors associated with student attrition and documented strategies aimed at improving retention. Findings were organized into thematic clusters, highlighting the use of machine learning technologies to predict academic risk, the influence of socioeconomic and psychosocial factors on dropout rates, and the effectiveness of institutional policies in fostering retention. The literature indicates that variables such as prior academic performance, self-efficacy, and access to financial resources are key predictors of attrition. Educational analytics tools, such as deep learning algorithms, have demonstrated high accuracy in early identification of at-risk students; however, their implementation faces constraints in rural areas or settings with limited technological infrastructure. This analysis underscores the importance of integrated strategies that combine technological, pedagogical, and psychosocial approaches. While advanced technologies offer notable advantages, their effectiveness and sustainability depend on their adaptability to diverse contexts and the integration of human factors into predictive models.

Keywords: *student attrition, academic retention, higher education, engineering, machine learning.*

1. Introducción

La deserción estudiantil en la educación superior es una problemática que afecta tanto a los estudiantes como a las instituciones educativas, generando implicaciones académicas, sociales y económicas (Miranda & Guzmán, 2017). Este fenómeno se relaciona con múltiples factores, que incluyen barreras académicas, limitaciones socioeconómicas y carencias en el soporte institucional. Para los estudiantes, el abandono implica una interrupción en sus metas profesionales y personales, mientras que, para las instituciones, supone pérdidas en términos de recursos invertidos y una disminución en indicadores clave como la tasa de graduación y la reputación académica (Silva & Sampaio, 2022).

En carreras universitarias de ingeniería y áreas técnicas, la situación es aún más crítica debido al nivel de exigencia de los programas y las dificultades que enfrentan los estudiantes en su transición académica. Factores como la preparación insuficiente en áreas fundamentales, la falta de habilidades de aprendizaje autónomo y las restricciones económicas contribuyen al riesgo de abandono. Además, el carácter técnico de estas carreras puede amplificar los desafíos, exigiendo estrategias más especializadas para mejorar las tasas de retención y apoyar a los estudiantes durante su trayectoria educativa (Huerta-Manzanilla et al., 2021; Pertegal-Felices et al., 2022).

El presente artículo se basa en una Revisión Sistemática de Literatura (SLR) realizada en la base de datos Scopus, diseñada para analizar los factores asociados a la deserción estudiantil y las estrategias de retención en carreras universitarias de ingeniería y áreas técnicas. El proceso de búsqueda y selección se realizó bajo criterios específicos, que incluyeron estudios publicados entre 2000 y 2024, en inglés y español, disponibles en acceso abierto, y enfocados en el contexto de la educación superior. Se identificaron 57 artículos relevantes, que fueron objeto de un análisis profundo para responder a tres preguntas clave: *¿cuáles son los enfoques temáticos predominantes en los estudios sobre deserción y retención?*, *¿qué factores relacionados con la deserción estudiantil en carreras universitarias de ingeniería y áreas técnicas han sido identificados en la literatura?* y *¿qué estrategias reportadas en la literatura han sido efectivas para mejorar la retención estudiantil en programas técnicos e ingeniería?*

El artículo se estructura en cuatro secciones. La primera aborda la metodología utilizada para la recopilación y análisis de los artículos seleccionados, detallando el proceso de búsqueda, los criterios de inclusión y exclusión, y las técnicas de clasificación aplicadas. En la segunda sección, se presentan los resultados obtenidos, organizados en clústeres temáticos que incluyen áreas como las tecnologías de aprendizaje automático para la predicción académica, los

factores asociados al rendimiento y el entorno, y las aplicaciones de la analítica educativa en estrategias de retención. La tercera sección discute los hallazgos en relación con estudios previos y analiza las áreas que requieren mayor atención, identificando desafíos y oportunidades para futuras investigaciones. Finalmente, se ofrecen conclusiones basadas en el análisis de los documentos seleccionados para este estudio.

2. Metodología

Se realizó una Revisión Sistemática de Literatura (SLR) para analizar y sintetizar la evidencia disponible sobre la deserción estudiantil y las estrategias de retención en carreras universitarias de ingeniería y áreas técnicas. Este enfoque metodológico asegura un proceso estructurado y transparente, garantizando que los resultados sean exhaustivos y estén respaldados por estudios relevantes. La SLR, reconocida por su utilidad en la identificación y evaluación de literatura científica, es ampliamente utilizada en investigaciones que abordan fenómenos complejos, como la deserción en educación superior, proporcionando una base sólida para generar conocimiento y diseñar intervenciones efectivas (Kitchenham & Charters, 2007; Petticrew & Roberts, 2006).

En este estudio se plantearon tres preguntas de investigación fundamentales. La primera busca determinar cómo se clasifican los documentos seleccionados en función de los enfoques y áreas temáticas relacionadas con la deserción estudiantil y la retención. La segunda se enfoca en identificar los factores más relevantes que influyen en la deserción estudiantil en carreras universitarias de ingeniería y áreas técnicas y la tercera en identificar que estrategias han sido efectivas para mejorar la retención estudiantil. Estas preguntas guían el análisis y permiten estructurar los hallazgos de manera que aporten respuestas claras y relevantes.

Para la búsqueda de literatura, se empleó la base de datos Scopus utilizando la cadena:

TITLE-ABS-KEY (retention AND dropout AND from AND university) AND PUBYEAR > 1999 AND PUBYEAR < 2025 AND (LIMIT-TO (DOCTYPE, "ar")) AND (LIMIT-TO (OA, "all")) AND (LIMIT-TO (LANGUAGE, "English") OR LIMIT-TO (LANGUAGE, "Spanish")) AND (EXCLUDE (SUBJAREA, "MEDI") OR EXCLUDE (SUBJAREA, "NURS") OR EXCLUDE (SUBJAREA, "PHAR") OR EXCLUDE (SUBJAREA, "HEAL"))

Esta búsqueda inicial identificó 507 documentos. A partir de estos resultados, se aplicaron criterios de inclusión y exclusión. Se consideraron únicamente artículos científicos publicados en inglés o español, disponibles en acceso abierto y relacionados con la educación superior, excluyendo aquellos enfocados en ciencias de la salud, farmacología, enfermería y áreas similares. Tras esta selección, se redujo el

número de documentos a 112, los cuales fueron evaluados en detalle según sus títulos y resúmenes, seleccionando 62 artículos. De estos, se accedió al texto completo de 57 documentos, que fueron sometidos a un análisis exhaustivo.

3. Resultados

En esta sección se presentan los hallazgos obtenidos a partir del análisis de los documentos seleccionados mediante la metodología de Revisión Sistemática de la Literatura (SLR). Los resultados se organizan considerando los clústeres identificados con el uso de la herramienta VOSviewer, la cual permitió agrupar las temáticas clave del tema investigado mediante el análisis de coocurrencia de palabras clave. Cada clúster fue categorizado y analizado de forma detallada, brindando una visión integral de las tendencias predominantes, los enfoques recurrentes y las áreas de oportunidad dentro del campo de estudio. A continuación, se realiza un análisis en relación con las preguntas de investigación planteadas:

P1: ¿Cómo se clasifican los documentos seleccionados según los enfoques y áreas temáticas relacionadas con la deserción estudiantil y la retención?

Los documentos seleccionados fueron clasificados mediante técnicas de análisis de coocurrencia de términos utilizando herramientas como VOSviewer. Este procedimiento permitió agrupar los estudios en clústeres temáticos, identificando áreas como el uso de aprendizaje automático

para la predicción y retención estudiantil, los factores asociados al rendimiento académico y la deserción en educación superior, y la aplicación de analítica educativa para diseñar estrategias de intervención. Este proceso responde a la primera pregunta de investigación, proporcionando una visión estructurada de las principales áreas de enfoque en la literatura revisada.

Análisis de coocurrencia de términos

La Figura 1 presenta un análisis de coocurrencia de términos en publicaciones académicas con una dimensión temporal que abarca desde 2021 hasta 2023. Los colores indican la concentración temporal de las investigaciones, destacando tendencias recientes y áreas de interés emergente. En las áreas relacionadas con aprendizaje automático y predicción académica, términos como "*adaptive boosting*" y "*decision trees*" aparecen asociados con los años más recientes, reflejando el crecimiento de estas técnicas avanzadas en el ámbito educativo. Por otro lado, conceptos vinculados al rendimiento académico y los entornos educativos, como "*higher education institutions*" y "*academic performance*," mantienen una presencia constante a lo largo del período, lo que sugiere su relevancia persistente en el análisis académico. Asimismo, la aparición de términos como "*covid-19*" hacia el final del espectro temporal resalta la influencia del contexto pandémico en los estudios relacionados con la educación, especialmente en áreas rurales y el impacto en el sector universitario.

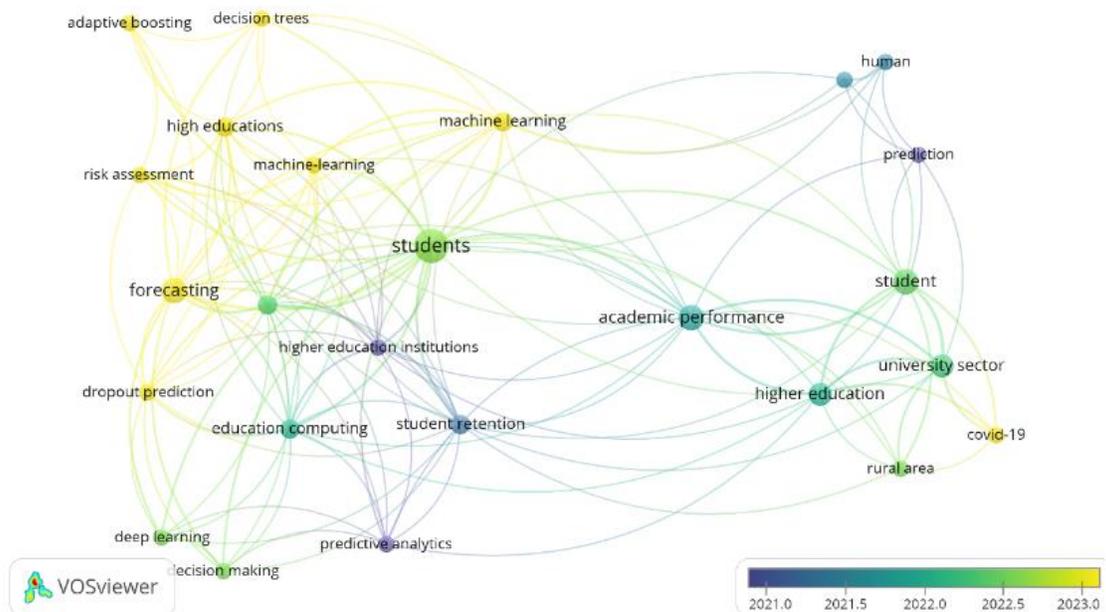


Figura 1: Análisis de coocurrencia de terminos (temporalidad).

El gráfico de co-ocurrencia, generado mediante VOSviewer (Figura 2), proporciona un análisis detallado de los términos relacionados con la educación superior, el rendimiento académico y el uso de tecnologías avanzadas para la predicción y el análisis de datos en el ámbito estudiantil. Este análisis permite identificar las principales áreas de investigación mediante la agrupación de términos en clústeres que reflejan temáticas específicas.

El primer clúster, identificado con el color rojo, se centra en el uso del aprendizaje automático en el análisis educativo.

Términos como "students", "machine learning", "decision trees", "adaptive boosting" y "risk assessment" dominan este grupo. La presencia de algoritmos como árboles de decisión y métodos de *boosting* sugiere que el enfoque principal está en la predicción del rendimiento de los estudiantes y la evaluación de riesgos académicos. Esto refleja un interés en la implementación de herramientas tecnológicas para abordar desafíos relacionados con la educación, utilizando técnicas de análisis de datos avanzadas.

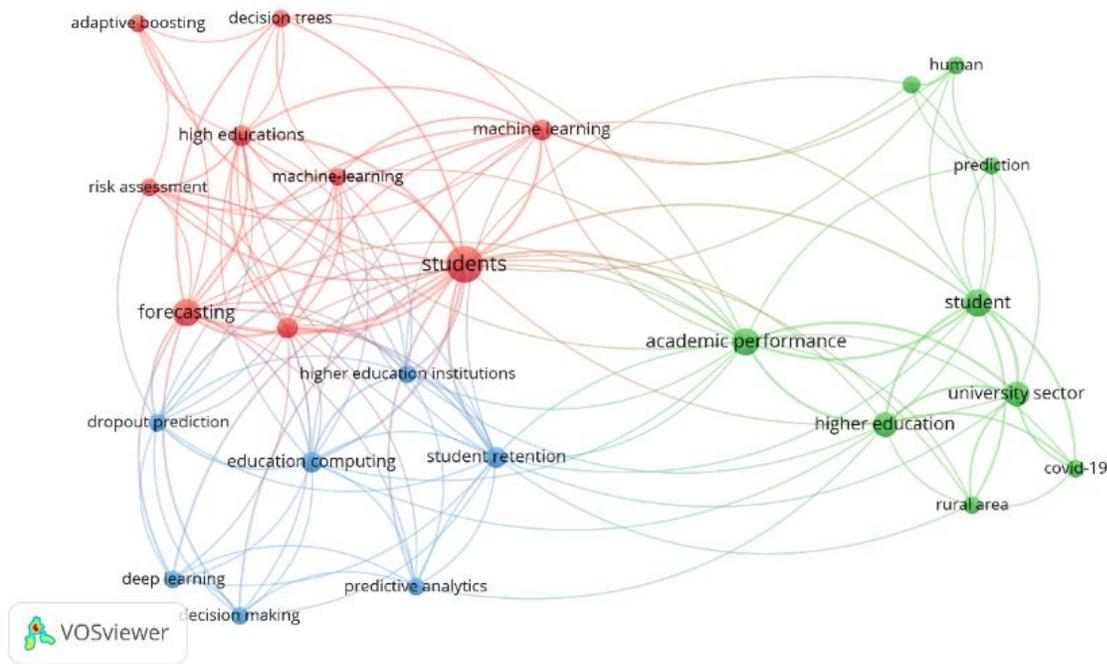


Figura 2: Gráfico de coocurrencia de términos.

El segundo clúster, representado en verde, agrupa términos relacionados con el rendimiento académico y el entorno del sector universitario. Conceptos como "academic performance", "higher education", "university sector" y "student" destacan como áreas clave de investigación. Este grupo muestra un enfoque en el análisis de los factores que afectan el rendimiento académico, incluyendo el impacto de la pandemia de COVID-19 y las particularidades de las áreas rurales. Esto sugiere una preocupación por comprender las dinámicas del aprendizaje en contextos diversos y su relación con el desempeño de los estudiantes.

El tercer clúster, identificado en azul, se orienta hacia la predicción de la deserción estudiantil y la analítica educativa. Términos como "dropout prediction", "student retention", "deep learning" y "education computing" indican un interés en el uso de tecnologías como el aprendizaje profundo para mejorar la retención estudiantil. Este clúster

enfaza la importancia de aplicar herramientas avanzadas de análisis para abordar uno de los mayores desafíos en la educación superior: la deserción. Esto refleja un compromiso con el uso de la tecnología para implementar estrategias efectivas en las instituciones educativas.

Los vínculos entre los clústeres muestran relaciones interdisciplinarias que conectan términos como "students" y "higher education", los cuales actúan como nodos centrales en el gráfico. Esto evidencia que los estudiantes y las instituciones de educación superior son el eje central de estudio, mientras que las herramientas tecnológicas se integran como soluciones prácticas para problemas como la deserción, la retención y el rendimiento. La conexión entre clústeres también destaca la integración de enfoques tecnológicos y académicos para generar soluciones más robustas y específicas.

En términos de tendencias emergentes, el gráfico muestra un creciente interés por las "*predictive analytics*" en el ámbito educativo, lo cual vincula el análisis de datos con la toma de decisiones estratégicas en las instituciones. La presencia de términos relacionados con el COVID-19 refleja la relevancia actual de estudiar los efectos de la pandemia en la educación superior. Asimismo, la inclusión de "*rural area*" sugiere un interés en contextos específicos y su relación con el rendimiento académico y la equidad en el acceso a la educación.

Análisis del Clúster Rojo: Tecnologías de Aprendizaje Automático para la Predicción Académica

Las tecnologías de aprendizaje automático han desempeñado un papel crucial en la predicción de la deserción estudiantil en educación superior. Estas herramientas permiten procesar grandes volúmenes de datos académicos, demográficos y conductuales, identificando patrones complejos que no son evidentes con métodos tradicionales. Los algoritmos más utilizados incluyen redes neuronales, árboles de decisión y Random Forest, que destacan por su precisión en la identificación de estudiantes en riesgo de abandono (Miranda & Guzmán, 2017; Oqaidi et al., 2022).

El análisis de los artículos, clasificados en este clúster, indica que una de las aplicaciones clave del aprendizaje automático es la identificación de factores asociados con la deserción. Variables como el desempeño académico previo (Goran et al., 2024), la participación en actividades extracurriculares y el acceso a recursos económicos (Marcq et al., 2024) se identificaron consistentemente como predictores significativos. En un estudio realizado en Chile, el uso de redes neuronales logró una precisión del 83 % en la predicción de deserción, destacando la influencia de factores como el puntaje de ingreso y las calificaciones de secundaria (Miranda & Guzmán, 2017). Por otro lado, en Estados Unidos, el modelo Random Forest alcanzó un 88 % de precisión al integrar métricas de interacción basadas en aplicaciones móviles y datos sociodemográficos, demostrando que los factores conductuales también son críticos para la predicción (Matz et al., 2023).

El uso de aprendizaje profundo ha mostrado avances relevantes, particularmente con modelos como las redes neuronales recurrentes (RNN) y de memoria a largo plazo (LSTM). Estas técnicas permiten analizar datos longitudinales, como patrones de asistencia y rendimiento académico, logrando precisiones superiores al 88 % (Uliyan et al., 2021). Además, la implementación de uplift modeling ha sido destacada como una herramienta efectiva para personalizar intervenciones de retención, enfocándose en estudiantes que tienen mayor probabilidad de beneficiarse de estrategias específicas, optimizando así la asignación de recursos (Olaya et al., 2020).

Desde una perspectiva metodológica, la integración de marcos como CRISP-DM con el Marco Lógico ha facilitado el análisis estructurado de los datos y el diseño de intervenciones efectivas. Esta combinación permite identificar no solo los factores que influyen en la deserción, sino también cómo estos interactúan, proporcionando una base sólida para estrategias basadas en evidencia (Flores et al., 2022). Asimismo, técnicas como el análisis de componentes principales y el clustering jerárquico han permitido clasificar a los estudiantes según perfiles de riesgo, lo que facilita el diseño de planes de intervención específicos para grupos con características similares (Hinojosa et al., 2022). En Filipinas, la combinación de análisis de supervivencia con modelos de ensamblaje permitió identificar variables críticas como el promedio general de calificaciones y las notas en materias fundamentales como matemáticas, lo que resaltó la importancia de enfoques interdisciplinarios para abordar la deserción (Patacsil, 2020). En tanto, en el ámbito de cursos en línea, el aprendizaje automático se ha utilizado para analizar las interacciones iniciales en plataformas digitales, demostrando su eficacia en la predicción temprana de abandono (Urteaga et al., 2020).

Análisis del Clúster Verde: Rendimiento Académico y Entornos Universitarios

El análisis del rendimiento académico y los entornos universitarios ha demostrado ser esencial para comprender y mitigar los factores que contribuyen a la deserción estudiantil en la educación superior. Según los artículos revisados, estos factores incluyen variables socioeconómicas, académicas, tecnológicas y psicosociales, que interactúan de manera compleja en diferentes contextos educativos.

La densidad de co-inscripción en programas de ingeniería, medida a través del análisis de redes y modelos de regresión logística, ha sido destacada como un indicador robusto de persistencia y graduación. Un estudio longitudinal en ocho universidades públicas de Estados Unidos demostró que los estudiantes con una mayor densidad de co-inscripción tienen probabilidades significativamente mayores de completar sus estudios. Este hallazgo resalta la importancia de promover cohortes académicas cohesionadas para mejorar las tasas de retención (Huerta-Manzanilla et al., 2021).

En áreas rurales, las barreras socioeconómicas y la infraestructura educativa limitada afectan considerablemente las tasas de deserción. Investigaciones realizadas en comunidades rurales han identificado la presión económica, el trabajo remunerado y las restricciones tecnológicas como factores determinantes. Las becas dirigidas y los programas de mentoría se presentan como estrategias eficaces para mitigar estas desigualdades y fomentar la retención (Asenjo et al., 2024).

El impacto de las modalidades educativas virtuales también ha sido ampliamente estudiado, especialmente en contextos de vulnerabilidad. Factores como la percepción de baja calidad de los contenidos académicos y las deficiencias tecnológicas han sido identificados como barreras significativas. En Colombia, un modelo de regresión logística multinomial destacó que la combinación de problemas financieros y acceso limitado a infraestructura tecnológica incrementa el riesgo de abandono académico. Estos hallazgos subrayan la necesidad de políticas integrales que fortalezcan tanto la accesibilidad tecnológica como la calidad de los contenidos educativos (Segovia et al., 2024).

Desde el aspecto psicológico, la autoeficacia y el aprendizaje autorregulado actúan como mediadores críticos en la intención de persistir académicamente. En Rumanía, se encontró que la satisfacción con la especialización académica y el apoyo social percibido están estrechamente vinculados a la retención estudiantil. La autoeficacia, en particular, actúa como un mediador clave entre estas variables, resaltando la necesidad de entornos educativos que refuercen estas capacidades (Cădariu & Rad, 2023).

El análisis de la resiliencia durante la pandemia de COVID-19 en Ecuador evidenció que los estudiantes con mayores niveles de resiliencia tenían menores probabilidades de abandonar sus estudios. Este hallazgo pone de relieve la importancia de factores socioculturales e interpersonales, así como de las estrategias institucionales que apoyen el bienestar integral de los estudiantes (Pertegal-Felices et al., 2022).

Desde la perspectiva de políticas institucionales, se ha demostrado que las ayudas financieras y asistenciales son las más efectivas para reducir la deserción. En Brasil, un modelo integral de evaluación propuso medir el impacto de estas políticas no solo en términos de permanencia, sino también en el rendimiento académico y el tiempo de graduación. Estas estrategias adaptadas a las características de las poblaciones estudiantiles permiten abordar las necesidades específicas de los estudiantes, maximizando su efectividad (Silva & Sampaio, 2022). Estas investigaciones subrayan la importancia de un enfoque multidimensional para abordar la deserción estudiantil. La integración de estrategias que consideren las necesidades académicas, tecnológicas, socioeconómicas y psicológicas es crucial para mejorar las tasas de retención y garantizar el éxito académico en la educación superior.

Análisis del Clúster Azul: Analítica Educativa y Predicción de Deserción

El aprendizaje automático representa un recurso clave para abordar la deserción estudiantil, al facilitar la identificación de patrones de riesgo y el diseño de intervenciones basadas en datos. Estas tecnologías han sido aplicadas en distintos contextos educativos, integrando variables académicas,

sociodemográficas y conductuales para construir modelos predictivos que logran anticipar el abandono con altos niveles de precisión (Urbina-Nájera et al., 2020).

En Chile, (Miranda & Guzmán, 2017) implementaron redes neuronales, árboles de decisión y redes bayesianas, alcanzando precisiones del 83 %. Factores como el puntaje en la Prueba de Selección Universitaria (PSU) y las notas promedio de secundaria se identificaron como los principales determinantes de la deserción. Por otro lado, modelos basados en cadenas de Markov, utilizados por (González-Campos et al., 2020), analizaron datos longitudinales, revelando que el 39 % de los abandonos ocurre en los primeros dos semestres. Este hallazgo subraya la necesidad de implementar intervenciones tempranas.

El aprendizaje profundo ha mostrado ser una técnica avanzada en la predicción del riesgo estudiantil. (Uliyan et al., 2021) utilizaron redes neuronales BLSTM combinadas con CRF, logrando precisiones superiores al 88 %. Este enfoque permite procesar secuencias de datos longitudinales, como calificaciones y asistencia, para identificar riesgos de manera más detallada. De manera complementaria, (Olaya et al., 2020) introdujeron el *uplift modeling*, una técnica diseñada para personalizar intervenciones dirigidas a estudiantes con alta probabilidad de responder favorablemente a programas de retención.

En instituciones como la Arab Open University, (Sayed, 2024) aplicó redes neuronales convolucionales (CNN) integrando datos del sistema de gestión de aprendizaje y del sistema de información estudiantil. Este enfoque alcanzó precisiones del 98.6 %, destacando variables como el desempeño inicial y la carga académica como predictores claves. Similarmente, (Oqaidi et al., 2022) destacaron la importancia de algoritmos como *Random Forest* y *Support Vector Machines* en la construcción de modelos de predicción eficaces, especialmente en contextos de alta diversidad sociodemográfica.

El análisis de componentes principales y el clustering jerárquico también han sido herramientas útiles para clasificar a los estudiantes según perfiles de riesgo. Estos métodos permiten identificar grupos específicos y diseñar intervenciones adaptadas a las características de cada grupo, como se observó en estudios realizados en México y Chile (Hinojosa et al., 2022; Urbina-Nájera et al., 2020). Además, se han utilizado técnicas de ensamblaje, como *Bagging* y *Boosting*, para combinar múltiples algoritmos y mejorar la precisión de las predicciones (Patacsil, 2020).

Desde una perspectiva metodológica, la integración del modelo CRISP-DM con el Marco Lógico ha permitido estructurar de manera efectiva el análisis de datos educativos. Este marco facilita la identificación de problemas y objetivos, proporcionando una guía para el

diseño de estrategias basadas en evidencia (Flores et al., 2022).

Las tecnologías de aprendizaje automático han transformado la forma en que las instituciones educativas abordan la deserción estudiantil. Estas herramientas no solo permiten anticipar riesgos, sino también diseñar estrategias de intervención basadas en datos específicos de cada institución, optimizando los recursos y mejorando las tasas de retención.

P2: ¿Qué factores relacionados con la deserción estudiantil en carreras universitarias de ingeniería y áreas técnicas han sido identificados en la literatura?

La literatura revisada evidencia que la deserción estudiantil en carreras universitarias de ingeniería y áreas técnicas está influenciada por una combinación de factores académicos, socioeconómicos, psicosociales y tecnológicos. En el ámbito académico, el desempeño previo en asignaturas clave como matemáticas y programación, junto con los puntajes en pruebas de ingreso como la PSU en Chile, se destacan como predictores del abandono estudiantil (Gallegos et al., 2018; Lázaro et al., 2020). La integración académica, medida por la interacción frecuente con profesores y compañeros, también se ha identificado como un elemento relevante en la retención, especialmente en los primeros años de formación (González-Campos et al., 2020; Shmeleva & Froumin, 2020). Sin embargo, las dificultades en asignaturas iniciales continúan siendo un factor crítico que incrementa las tasas de abandono (Sacalã et al., 2021; Vidal et al., 2022).

En el plano socioeconómico, la insuficiencia de recursos financieros representa una de las principales barreras para la continuidad educativa, particularmente en estudiantes provenientes de entornos vulnerables (Cocoradã et al., 2021; Segovia et al., 2024).

El acceso a becas y créditos, por otro lado, ha mostrado ser un recurso fundamental para mitigar las desigualdades económicas y mejorar las tasas de retención (Branson & Whitelaw, 2024; Gallegos et al., 2018). Desde una perspectiva psicosocial, la motivación intrínseca y la autoeficacia personal destacan como variables asociadas a la permanencia estudiantil, mientras que el apoyo social y altos niveles de resiliencia refuerzan la capacidad de los estudiantes para afrontar las demandas académicas (Cădariu & Rad, 2023; Pertegal-Felices et al., 2022; Vidal et al., 2022).

Los avances tecnológicos en analítica educativa, como el uso de algoritmos de aprendizaje automático, han permitido predecir con alta precisión a los estudiantes en riesgo de deserción. Sin embargo, estas herramientas enfrentan limitaciones en contextos con infraestructura tecnológica restringida (González-Campos et al., 2020; Sayed, 2024).

Asimismo, en modalidades virtuales, factores como la percepción de baja calidad en los contenidos y la falta de interacción social han mostrado un impacto negativo en la retención (García Aretio, 2019; Segovia et al., 2024). En conjunto, estos hallazgos subrayan la necesidad de estrategias integrales que consideren la interacción entre estos factores para reducir las tasas de abandono y fomentar la continuidad académica.

P3: ¿Qué estrategias reportadas en la literatura han sido efectivas para mejorar la retención estudiantil en programas técnicos e ingeniería?

La literatura revisada identifica diversas estrategias implementadas en programas técnicos e ingeniería que han demostrado efectividad para mejorar la retención estudiantil. En el ámbito académico, los programas de tutorías personalizadas y nivelación académica han sido efectivos en reducir las tasas de abandono, especialmente en los primeros años de estudio. En Filipinas, el uso de modelos predictivos como árboles de decisión permitió identificar a estudiantes en riesgo y aplicar intervenciones tempranas, logrando una disminución significativa en las tasas de deserción (Patacsil, 2020). De manera similar, en Chile, el programa "Me quedo en la universidad" se centró en el apoyo académico y emocional, mostrando resultados positivos en la retención de estudiantes de ingeniería civil biomédica (Castillo et al., 2019).

La integración social también se presenta como una estrategia clave. Investigaciones realizadas en México y Rusia destacan que los estudiantes que participan activamente en actividades extracurriculares y mantienen interacciones regulares con profesores y compañeros tienen mayores probabilidades de completar sus estudios (Barragán Moreno & González Támara, 2017; Shmeleva & Froumin, 2020). En este sentido, la promoción de actividades que fortalezcan la cohesión estudiantil y la creación de redes de apoyo social son fundamentales.

En el ámbito tecnológico, los algoritmos de aprendizaje automático han optimizado los esfuerzos por identificar estudiantes en riesgo. Herramientas como *Random Forest*, *Support Vector Machines* y *XGBoost* han mostrado alta precisión en la predicción del abandono, permitiendo diseñar intervenciones específicas. Por ejemplo, en la Pontificia Universidad Católica del Ecuador, el uso de estos modelos predictivos mejoró significativamente la retención estudiantil mediante la personalización de estrategias de intervención (Guanin-Fajardo et al., 2024; Oqaidi et al., 2022).

Por último, se destaca la implementación de políticas de apoyo financiero y académico. En Colombia y Rumania, las becas específicas y los programas de mentoría han reducido las tasas de abandono, especialmente entre estudiantes de

entornos vulnerables (Acevedo, 2023; Cocoradă et al., 2021). En general, la efectividad de estas estrategias depende de su capacidad para adaptarse a las necesidades específicas de los estudiantes y de los contextos institucionales donde se aplican.

4. Discusión

El análisis de los factores asociados a la deserción estudiantil y las estrategias de retención en la educación superior revela oportunidades significativas para ampliar el alcance de las investigaciones actuales. Si bien los modelos predictivos y las intervenciones institucionales han logrado avances en la comprensión y mitigación del abandono, persisten áreas que requieren mayor atención para lograr un abordaje más integral.

Uno de los aspectos identificados es la limitada adaptabilidad de los modelos predictivos a contextos diversos. La mayoría de los estudios se concentran en instituciones con infraestructura tecnológica avanzada, dejando un margen reducido para su implementación en universidades rurales o en regiones con recursos limitados. Este enfoque restringido limita el potencial de estas herramientas para abordar las dinámicas específicas de las comunidades educativas menos favorecidas (Miranda & Guzmán, 2017; Oqaidi et al., 2022)

Además, los factores psicosociales, como la autoeficacia, la resiliencia y la motivación, son mencionados de manera superficial en los estudios revisados. Aunque estas dimensiones influyen significativamente en la permanencia estudiantil, su integración en las estrategias de retención y modelos predictivos no ha sido suficientemente desarrollada, dejando de lado elementos clave en la experiencia del estudiante (Cădariu & Rad, 2023; Pertegal-Felices et al., 2022).

En el ámbito de la educación virtual e híbrida, las investigaciones se han centrado principalmente en el impacto de los problemas tecnológicos y de accesibilidad. Sin embargo, los estudios sobre cómo mejorar la interacción social y académica en estas modalidades aún son limitados. Elementos como la participación activa, la colaboración en línea y el apoyo social son esenciales para fortalecer la retención en estos entornos y aún no han sido explorados a profundidad (Segovia et al., 2024; Urteaga et al., 2020).

Otro aspecto es la falta de evaluaciones longitudinales que permitan medir el impacto a largo plazo de las estrategias implementadas. Aunque muchas intervenciones muestran resultados prometedores en las etapas iniciales, pocos estudios han documentado su sostenibilidad y efectividad con el paso del tiempo, dificultando el diseño de políticas educativas duraderas y escalables (Flores et al., 2022; Silva & Sampaio, 2022). Por último, la integración de enfoques

interdisciplinarios que combinen análisis cuantitativos y cualitativos sigue siendo escasa. Este tipo de aproximación podría ofrecer una visión más completa sobre las causas subyacentes del abandono y ayudar a diseñar estrategias que consideren tanto las características individuales como las institucionales (Hinojosa et al., 2022; Olaya et al., 2020).

El panorama actual del estudio sobre deserción estudiantil sugiere que es crucial ampliar el enfoque para incluir dimensiones que hasta ahora han sido subrepresentadas. Abordar estas áreas permitirá no solo mejorar la comprensión del fenómeno, sino también diseñar estrategias más efectivas y sostenibles que respondan a las necesidades específicas de los estudiantes y las instituciones.

Por último, se destaca la implementación de políticas de apoyo financiero y académico. En Colombia y Rumania, las becas específicas y los programas de mentoría han reducido las tasas de abandono, especialmente entre estudiantes de entornos vulnerables (Acevedo, 2023; Cocoradă et al., 2021). En general, la efectividad de estas estrategias depende de su capacidad para adaptarse a las necesidades específicas de los estudiantes y de los contextos institucionales donde se aplican.

5. Conclusiones

La revisión sistemática identificó factores documentados en la literatura que influyen en la deserción estudiantil en carreras de ingeniería y áreas técnicas, así como estrategias dirigidas a mejorar la retención. Entre los factores más frecuentes se encuentran el rendimiento académico previo, las habilidades de aprendizaje autónomo y el acceso a recursos económicos. Además, las herramientas de aprendizaje automático, como los algoritmos de clasificación y modelos de aprendizaje profundo, han mostrado precisión en la identificación temprana de estudiantes en riesgo, aunque su implementación presenta dificultades en instituciones con infraestructura tecnológica limitada.

Las estrategias revisadas destacan la necesidad de abordar de manera conjunta elementos tecnológicos, pedagógicos y sociales para reducir las tasas de abandono. Sin embargo, una parte importante de los estudios se enfoca en contextos con recursos tecnológicos avanzados, dejando áreas poco exploradas en entornos rurales o con menores recursos. También se observa que variables relacionadas con aspectos psicosociales, como la motivación y el apoyo social, no son comúnmente integradas en los modelos predictivos revisados.

La ausencia de análisis longitudinales limita la evaluación de la efectividad de las estrategias a largo plazo. Para avanzar en el conocimiento del fenómeno de la deserción, es esencial ampliar las investigaciones hacia contextos menos

estudiados y adaptar las herramientas disponibles a diferentes escenarios educativos, lo que permitirá un abordaje más inclusivo y aplicable.

Referencias

- Acevedo, F. (2023). The deficient factual basis of the main explanatory models of dropout in higher education. *Journal of Education and Learning*, 17(2), 241–248. <https://doi.org/10.11591/edulearn.v17i2.20756>
- Asenjo, E., Santos, L., Puican, L., Ventura, F., Huanca, L., Valladolid, A., & Hinojosa, C. (2024). Fostering equity in rural education: a literature review on student dropout and retention strategies. *Revista de Gestao Social e Ambiental*, 18(1). <https://doi.org/10.24857/RGSA.V18N1-083>
- Barragán Moreno, S. P., & González Támara, L. (2017). Approach to student dropouts from the perspective of social and academic integration. *Revista de La Educacion Superior*, 46(183), 63–86. <https://doi.org/10.1016/j.resu.2017.05.004>
- Branson, N., & Whitelaw, E. (2024). South African student retention during 2020: Evidence from system-wide higher education institutional data. *South African Journal of Economics*, 92(1), 9–30. <https://doi.org/10.1111/saje.12361>
- Cădariu, I.-E., & Rad, D. (2023). Predictors of Romanian Psychology Students' Intention to Successfully Complete Their Courses—A Process-Based Psychology Theory Approach. *Behavioral Sciences*, 13(7). <https://doi.org/10.3390/bs13070549>
- Castillo, P., Morales, T., & Miranda, C. (2019). Evaluation of a psycho-social support program about concepts of persistence and university retention. *Revista Brasileira de Educacao*, 24, 1–24. <https://doi.org/10.1590/S1413-24782019240058>
- Cocoradă, E., Curtu, A. L., Năstasă, L. E., & Vorovencii, I. (2021). Dropout intention, motivation and socio-demographics of forestry students in Romania. *Forests*, 12(5). <https://doi.org/10.3390/f12050618>
- Flores, V., Heras, S., & Julián, V. (2022). A New Methodological Framework for Project Design to Analyse and Prevent Students from Dropping Out of Higher Education. *Electronics (Switzerland)*, 11(18). <https://doi.org/10.3390/electronics11182902>
- Gallegos, J. A., Campos, N. A., Canales, K. A., & González, E. N. (2018). Determining factors of university dropout. A case of the faculty of economy and administration sciences of the Catholic University of the Most Holy Conception (Chile). *Formacion Universitaria*, 11(3), 11–18. <https://doi.org/10.4067/S0718-50062018000300011>
- García Aretio, L. (2019). The problem with distance education dropout rate. Answers from the Mediated Educational Dialogue. *RIED-Revista Iberoamericana de Educacion a Distancia*, 22(1), 245–270. <https://doi.org/10.5944/ried.22.1.22433>
- González-Campos, J. A., Carvajal-Muquillaza, C. M., & Aspeé-Chacón, J. E. (2020). Modelación de la deserción universitaria mediante cadenas de Markov. *Uniciencia*, 34(1), 129–146. <https://www.redalyc.org/articulo.oa?id=475962995008>
- Goran, R., Jovanovic, L., Bacanin, N., Stankovic, M. S., Simic, V., Antonijevic, M., & Zivkovic, M. (2024). Identifying and Understanding Student Dropouts Using Metaheuristic Optimized Classifiers and Explainable Artificial Intelligence Techniques. *IEEE Access*, 12, 122377–122400. <https://doi.org/10.1109/ACCESS.2024.3446653>
- Guanin-Fajardo, J. H., Guaña-Moya, J., & Casillas, J. (2024). Predicting Academic Success of College Students Using Machine Learning Techniques. *Data*, 9(4). <https://doi.org/10.3390/data9040060>
- Hinojosa, M., Derpich, I., Alfaro, M., Ruete, D., Caroca, A., & Gatica, G. (2022). Procedimento de agrupamento de alunos de acordo com o risco de evasão para melhorar a gestão estudiantil no ensino superior. *Texto Livre*, 15, e37275. <https://doi.org/10.35699/1983-3652.2022.37275>
- Huerta-Manzanilla, E. L., Ohland, M. W., & Peniche-Vera, R. D. R. (2021). Co-enrollment density predicts engineering students' persistence and graduation: College networks and logistic regression analysis. *Studies in Educational Evaluation*, 70. <https://doi.org/10.1016/j.stueduc.2021.101025>
- Kitchenham, B., & Charters, S. (2007). Guidelines for performing Systematic Literature Reviews in Software Engineering. 2.
- Lázaro, N., Callejas, Z., & Griol, D. (2020). Factors that affect student desertion in careers in Computer Engineering profile. *Revista Fuentes*, 22(1), 105–126. <https://doi.org/10.12795/revistafuentes.2020.v22.i1.09>
- Marcq, K., Donayre, E. J. C., & Braeken, J. (2024). The role of item format in the PISA 2018 mathematics literacy assessment: A cross-country study. *Studies in Educational Evaluation*, 83, 101401. <https://doi.org/https://doi.org/10.1016/j.stueduc.2024.101401>
- Matz, S. C., Bukow, C. S., Peters, H., Deacons, C., & Stachl, C. (2023). Using machine learning to predict student retention from socio-demographic characteristics and app-based engagement metrics. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-32484-w>
- Miranda, M. A., & Guzmán, J. (2017). Análisis de la deserción de estudiantes universitarios usando técnicas de minería de datos. *Formacion Universitaria*, 10(3), 61–68. <https://doi.org/10.4067/S0718-50062017000300007>

- Olaya, D., Vásquez, J., Maldonado, S., Miranda, J., & Verbeke, W. (2020). Uplift Modeling for preventing student dropout in higher education. *Decision Support Systems*, 134. <https://doi.org/10.1016/j.dss.2020.113320>
- Oqaidi, K., Aouhassi, S., & Mansouri, K. (2022). Towards a Students' Dropout Prediction Model in Higher Education Institutions Using Machine Learning Algorithms. *International Journal of Emerging Technologies in Learning*, 17(18), 103–117. <https://doi.org/10.3991/ijet.v17i18.25567>
- Patacsil, F. F. (2020). Survival analysis approach for early prediction of student dropout using enrollment student data and ensemble models. *Universal Journal of Educational Research*, 8(9), 4036–4047. <https://doi.org/10.13189/ujer.2020.080929>
- Portegal-Felices, M. L., Valdivieso-Salazar, D. A., Espín-León, A., & Jimeno-Morenilla, A. (2022). Resilience and Academic Dropout in Ecuadorian University Students during COVID-19. *Sustainability (Switzerland)*, 14(13). <https://doi.org/10.3390/su14138066>
- Petticrew, M., & Roberts, H. (2006). Why Do We Need Systematic Reviews? In *Systematic Reviews in the Social Sciences* (pp. 1–26). Wiley online Library. <https://doi.org/https://doi.org/10.1002/9780470754887.ch1>
- Sacală, M.-D., Pătărlăgeanu, S. R., Popescu, M.-F., & Constantin, M. (2021). Econometric research of the mix of factors influencing first-year students' dropout decision at the faculty of agri-food and environmental economics. *Economic Computation and Economic Cybernetics Studies and Research*, 55(3), 203–220. <https://doi.org/10.24818/18423264/55.3.21.13>
- Sayed, M. (2024). Student Progression and Dropout Rates Using Convolutional Neural Network: A Case Study of the Arab Open University. *Journal of Advanced Computational Intelligence and Intelligent Informatics*, 28(3), 668–678. <https://doi.org/10.20965/jaciii.2024.p0668>
- Segovia, N., Said Hung, E., & Aguilera, F. J. (2024). Abandono en la educación superior virtual colombiana: factores de riesgo para grupos vulnerables. *Revista Colombiana de Educación*, 90, 261–284. <https://doi.org/10.17227/rce.num90-15581>
- Shmeleva, E., & Froumin, I. (2020). Factors of Attrition among Computer Science and Engineering Undergraduates in Russia. *Voprosy Obrazovaniya / Educational Studies Moscow*, 3, 56–74. <https://doi.org/10.17323/1814-9545-2020-3-110-136>
- Silva, P. T. de F. e, & Sampaio, L. M. B. (2022). Student retention policies in higher education: reflections from a literature review for the Brazilian context. *Revista de Administração Pública*, 56(5), 603–631. <https://doi.org/10.1590/0034-761220220034x>
- Uliyan, D., Aljaloud, A. S., Alkhalil, A., Amer, H. S. A., Mohamed, M. A. E. A., & Alogali, A. F. M. (2021). Deep Learning Model to Predict Students Retention Using BLSTM and CRF. *IEEE Access*, 9, 135550–135558. <https://doi.org/10.1109/ACCESS.2021.3117117>
- Urbina-Nájera, A. B., Camino-Hampshire, J. C., & Cruz Barbosa, R. (2020). University dropout: Prevention patterns through the application of educational data mining. *RELIEVE - Revista Electronica de Investigacion y Evaluacion Educativa*, 26(1), 1–19. <https://doi.org/10.7203/relieve.26.1.16061>
- Urteaga, I., Siri, L., & Garófalo, G. (2020). Early dropout prediction via machine learning in professional online courses. *RIED-Revista Iberoamericana de Educacion a Distancia*, 23(2), 147–167. <https://doi.org/10.5944/ried.23.2.26356>
- Vidal, J., Gilar-Corbi, R., Pozo-Rico, T., Castejón, J.-L., & Sánchez-Almeida, T. (2022). Predictors of University Attrition: Looking for an Equitable and Sustainable Higher Education. *Sustainability (Switzerland)*, 14(17). <https://doi.org/10.3390/su141710994>

Conflicto de intereses

El autor ha declarado que no existe conflicto de intereses en esta obra.

Nota del Editor:

Descargo de responsabilidad: Los datos, declaraciones, opiniones contenidas en el documento son responsabilidad únicamente de los autores y no de la *Revista Científica FINIBUS – Ingeniería, Industria y Arquitectura*. La Revista y sus editores renuncian a toda responsabilidad por daño a persona o propiedad resultante de los métodos, instrucciones, producto o idea mencionado en el contenido.



Derechos de autor 2025. Revista Científica FINIBUS - ISSN: 2737-6451.

Esta obra está bajo una licencia: Internacional Creative Commons Atribución-NoComercial-CompartirIgual 4.0

