



Doi: <https://doi.org/10.70577/asce.v5i1.682>

**Recibido:** 2026-01-05

**Aceptado:** 2026-01-13

**Publicado:** 2026-02-19

## **Barreras de ingreso, IA predictiva y estrategias innovadoras de retención estudiantil en educación superior de Esmeraldas**

### **Entry Barriers, Predictive AI Models, and Innovative Student Retention Strategies in Higher Education in Esmeraldas**

#### **Autores**

**Mariuxi Lissette Arroyo Montaña<sup>1</sup>**

[mariuxi.arroyo.montano@utelvt.edu.ec](mailto:mariuxi.arroyo.montano@utelvt.edu.ec)

<https://orcid.org/0009-0001-5068-3546>

**Universidad Técnica Luis Vargas Torres**  
Esmeraldas-Ecuador

**Elayne Yanin Tenorio Canchingre<sup>2</sup>**

[elayne.tenorio.canchingre@utelvt.edu.ec](mailto:elayne.tenorio.canchingre@utelvt.edu.ec)

<https://orcid.org/0009-0001-2217-6352>

**Universidad Técnica Luis Vargas Torres**  
Esmeraldas-Ecuador

**Sara Sophie Mendoza Hernández<sup>3</sup>**

[sara.mendoza.hernandez@utelvt.edu.ec](mailto:sara.mendoza.hernandez@utelvt.edu.ec)

<https://orcid.org/0009-0009-4847-8285>

**Universidad Técnica Luis Vargas Torres**  
Esmeraldas-Ecuador

**Rita Jesús Ramírez Guerrero<sup>4</sup>**

[ritaramirezesla@gmail.com](mailto:ritaramirezesla@gmail.com)

<https://orcid.org/0009-0001-6784-6954>

**Unidad Educativa Eloy Alfaro**  
Esmeraldas-Ecuador

**Karen Gabriela Perugachi Montaña<sup>5</sup>**

[karen.perugachi.montano@utelvt.edu.ec](mailto:karen.perugachi.montano@utelvt.edu.ec)

<https://orcid.org/0009-0000-5044-6391>

**Universidad Técnica Luis Vargas Torres**  
Esmeraldas-Ecuador

#### **Cómo citar**

Arroyo Montaña, M. L., Tenorio Canchingre, E. Y., Mendoza Hernández, S. S., Ramírez Guerrero, R. J., & Perugachi Montaña, K. G. (2026). Barreras de ingreso, IA predictiva y estrategias innovadoras de retención estudiantil en educación superior de Esmeraldas. *ASCE MAGAZINE*, 5(1), 2012–2032.



---

## Resumen

Esta revisión bibliográfica integra evidencia sobre barreras de ingreso, modelos predictivos basados en inteligencia artificial y estrategias innovadoras de retención estudiantil en educación superior, con énfasis en su aplicabilidad institucional a la Universidad Técnica Luis Vargas Torres de Esmeraldas, los resultados sugieren que la permanencia se configura por vulnerabilidades iniciales y condicionantes de acceso, y que el rendimiento de la predicción depende del tipo de datos disponibles y del momento del semestre en que se estima el riesgo, los modelos contruidos con datos de matrícula desde el inicio aportan utilidad operativa con desempeño moderado, mientras que los modelos alimentados con trazas de plataformas virtuales tienden a mejorar conforme se acumula evidencia conductual semanal, además, la predicción adquiere valor institucional cuando se integra en un circuito cerrado que vincula identificación temprana con retroalimentación y apoyo personalizado, con protocolos claros de seguimiento, la evidencia aplicada muestra asociaciones entre alertas tempranas, contacto focalizado y soportes tecnológicos, como asistentes virtuales, con mejoras en engagement y desempeño, por consiguiente, la discusión enfatiza que la analítica debe interpretarse con cautela por la naturaleza multidimensional del compromiso, y que su implementación requiere gobernanza de datos, salvaguardas de privacidad, legitimidad ética y auditoría de equidad para evitar daños diferenciales en subgrupos, en conjunto, se respalda una estrategia por fases que combine perfilamiento de ingreso, predicción progresiva, explicabilidad y un portafolio evaluable de intervenciones articuladas con servicios de apoyo y mecanismos de ayuda financiera.

**Palabras clave:** Educación superior, Retención estudiantil, Deserción, Modelos predictivos, Analítica de aprendizaje, Minería de datos educativa.



## Abstract

This literature review examines barriers to entry, AI-based predictive models, and innovative student retention strategies in higher education, emphasizing institutional applicability to the Universidad Técnica Luis Vargas Torres de Esmeraldas. Evidence indicates that retention is shaped by structural entry barriers and early academic vulnerability, and that predictive performance depends strongly on data availability and timing. Models trained “from day one” using enrollment data provide operationally useful but moderate accuracy, while models fed with learning management system traces improve substantially as behavioral evidence accumulates across weeks. Findings also show that prediction becomes institutionally meaningful only when embedded in a closed-loop process that links early identification to timely feedback and tailored support actions. Interventions such as early warning messaging, targeted outreach, and technology-mediated assistance (e.g., chatbots) are associated with improvements in engagement and academic outcomes, suggesting scalable pathways for first-year support. Discussion-focused studies underline that learning analytics must be interpreted cautiously, given the multi-dimensional nature of engagement, and must be governed through transparent data practices, privacy safeguards, ethical legitimacy, and fairness auditing to avoid differential harms across student subgroups. Overall, the review supports a phased institutional strategy combining entry profiling, progressively updated risk prediction, explainability, and a portfolio of evaluable interventions aligned with student support services and financial aid mechanisms.

**Keywords:** Higher education, Student retention, Dropout prediction, Learning analytics, Educational data mining, Early warning systems.

---

## Introducción

Las barreras de ingreso y permanencia en educación superior tienden a expresarse como trayectorias educativas frágiles, con acumulación de desventajas por condiciones económicas, responsabilidades familiares y exigencias laborales, además de tensiones institucionales vinculadas a admisión, financiamiento y apoyos, en el caso ecuatoriano, los análisis recientes sostienen que el acceso continúa condicionado por desigualdades sociales, económicas y territoriales, y que la garantía efectiva del derecho exige políticas más integrales e inclusivas, en virtud de que la ampliación normativa no asegura por sí sola condiciones reales de ingreso y continuidad, cabe resaltar que, desde la perspectiva estudiantil, se han descrito obstáculos que afectan el desarrollo académico y pueden derivar en abandono, con énfasis en circunstancias personales y familiares, y por consiguiente, para un contexto como la Universidad Técnica Luis Vargas Torres de Esmeraldas, donde la vulnerabilidad territorial y socioeconómica puede intensificar el riesgo, resulta estratégico asumir el ingreso como un punto crítico de intervención institucional, no solo como un trámite administrativo, sino como el inicio de un acompañamiento estructurado y focalizado (Castillo Lluguay & Romero Flores, 2025; Silva-Martínez et al., 2023).

En esa misma línea, la retención estudiantil ha evolucionado desde modelos generales de “apoyo” hacia enfoques de identificación temprana basados en datos, donde la analítica de aprendizaje se posiciona como un marco para comprender señales de compromiso, desempeño y continuidad, y para activar apoyos en momentos de alta sensibilidad académica, por consiguiente, la evidencia sintetizada en revisiones sistemáticas muestra que existen múltiples aproximaciones de analítica que se orientan a la continuidad y culminación, aunque persisten limitaciones por falta de evidencia robusta a gran escala, y de manera complementaria, los análisis bibliométricos y de contenido han advertido que el campo ha crecido con fuerza, pero con desafíos persistentes para conectar la medición con mejoras reales del aprendizaje, y en virtud de ello, la prevención de deserción mediante analítica exige no solo modelos, sino decisiones institucionales, gobernanza de datos y traducción pedagógica de resultados (Ifenthaler & Yau, 2020; Guzmán-Valenzuela et al., 2021; de Oliveira et al., 2021).

De forma más específica, los modelos predictivos con inteligencia artificial se han consolidado como instrumentos para estimar riesgo de deserción o bajo rendimiento a partir de variables académicas, sociodemográficas y de interacción digital, y en ese marco, las revisiones en minería

de datos educativa y analítica predictiva han propuesto taxonomías de algoritmos, factores y entornos de aprendizaje, resaltando que la utilidad institucional depende de la calidad de los datos, del manejo del desbalance de clases y de la interpretación de predictores, cabe resaltar que el avance reciente incluye propuestas con enfoques de explicabilidad, orientadas a justificar por qué un estudiante es clasificado como de riesgo, y por consiguiente, el componente técnico debe quedar subordinado a decisiones de acompañamiento, equidad y trazabilidad de acciones, especialmente cuando se pretende implementar sistemas en universidades públicas con heterogeneidad estudiantil marcada (Shafiq et al., 2022; Mustofa et al., 2025).

En términos de efectividad, el valor de los modelos predictivos se concreta cuando se articulan con intervenciones, ya que la predicción sin respuesta institucional tiende a convertirse en una etiqueta inactiva, en virtud de ello, la evidencia meta-analítica disponible reporta que las intervenciones basadas en analítica pueden mejorar efectos de aprendizaje en un conjunto amplio de estudios empíricos, y de forma aplicada, se han propuesto sistemas de alerta temprana con intervenciones personalizadas, bajo marcos socio-técnicos que integran modelos, protocolos de contacto y acciones culturalmente pertinentes, por consiguiente, para instituciones que buscan retener, el punto crítico no es solo alcanzar métricas de desempeño predictivo, sino diseñar rutas de intervención sostenibles, evaluables y sensibles al contexto (Liu et al., 2025; Chang et al., 2025).

En el plano operativo, las estrategias innovadoras de retención suelen combinar señales tempranas y acciones de baja fricción, como contacto proactivo ante no entrega de evaluaciones iniciales, tutorías focalizadas y acompañamiento oportuno antes de hitos administrativos, cabe resaltar que este tipo de apoyo dirigido se ha reportado como una vía para mejorar permanencia mediante identificación simple y acción temprana, lo cual resulta coherente con la lógica de alerta temprana, y por consiguiente, para la Universidad Técnica Luis Vargas Torres de Esmeraldas, un enfoque integrado requiere mapear barreras de ingreso, definir variables disponibles para predicción, y construir un circuito de intervención que priorice estudiantes con mayor vulnerabilidad desde el primer ciclo, evitando que la intervención dependa de diagnósticos tardíos al cierre del semestre (Linden, 2022; Chang et al., 2025).

En virtud de lo anterior, el objetivo general de la investigación es analizar la evidencia reciente sobre barreras de ingreso, modelos predictivos con IA y estrategias innovadoras de retención estudiantil en educación superior, con énfasis en su aplicabilidad institucional a la Universidad

Técnica Luis Vargas Torres de Esmeraldas, y por consiguiente, se plantean como objetivos específicos identificar barreras de acceso y permanencia reportadas en la literatura, describir enfoques y variables usadas en predicción de riesgo, y sintetizar estrategias de intervención con orientación a implementación institucional, la pregunta de investigación que guía el estudio es, ¿qué barreras de ingreso se asocian con mayor vulnerabilidad de permanencia, qué enfoques predictivos con IA resultan más pertinentes según el tipo de datos institucionales disponibles, y qué estrategias innovadoras de retención muestran evidencia de efectividad para contextos de educación superior comparables al de la Universidad Técnica Luis Vargas Torres de Esmeraldas?

### **Material y métodos**

Se realizó una revisión bibliográfica con enfoque narrativo y procedimientos sistematizados, orientada a integrar evidencia sobre barreras de ingreso, modelos predictivos con inteligencia artificial, y estrategias innovadoras de retención estudiantil en educación superior, con aplicabilidad al contexto de la Universidad Técnica Luis Vargas Torres de Esmeraldas, en virtud de que el fenómeno combina dimensiones estructurales de acceso y permanencia con decisiones institucionales basadas en datos, por consiguiente se delimitó el periodo 2020–2025, se priorizaron documentos con disponibilidad de texto completo y DOI, y se definieron tres núcleos temáticos para la extracción y síntesis, barreras de acceso e ingreso con implicación en continuidad académica, predicción de riesgo de deserción o bajo rendimiento mediante analítica de aprendizaje, minería de datos educativa o aprendizaje automático, y estrategias de retención con componente de intervención, retroalimentación, tutoría, apoyo financiero, tableros o acompañamiento, cabe resaltar que la búsqueda se diseñó para recuperar tanto evidencia empírica como revisiones y meta-análisis, con el fin de sostener un marco conceptual sólido y, a la vez, incorporar resultados cuantificables y criterios prácticos de implementación institucional.

La búsqueda se ejecutó en cuatro fuentes, SCOPUS, Web of Science, SciELO y Google Académico, aplicando combinaciones equivalentes en inglés y español, con filtros por año, y con operadores booleanos ajustados a cada plataforma, por consiguiente en SCOPUS y Web of Science se priorizó la consulta por título, resumen y palabras clave, mientras que en SciELO y Google Académico se utilizó una estrategia combinada por relevancia y coincidencia textual, con verificación manual de elegibilidad, y cabe resaltar que se registraron las cadenas de búsqueda



finales utilizadas por base y por idioma, de modo que el proceso sea reproducible, lo cual se presenta en la Tabla 1.

El proceso de selección se realizó por etapas, primero cribado de título y resumen para descartar duplicados, documentos fuera del periodo, y estudios no relacionados con educación superior, luego lectura a texto completo para verificar criterios de inclusión, por consiguiente se incluyeron revisiones sistemáticas, meta-análisis, estudios cuantitativos, cualitativos y mixtos, además de estudios de caso institucionales, siempre que abordaran al menos uno de los componentes del marco temático, y que reportaran variables, procedimientos y resultados con claridad suficiente para comparación, cabe resaltar que se excluyeron textos centrados en educación básica o formación corporativa, documentos sin acceso al texto completo, publicaciones sin trazabilidad metodológica mínima, y trabajos que mencionaran deserción o retención de manera tangencial sin aportar evidencia, además, cuando un estudio presentaba modelos predictivos, se exigió que informara al menos variables clave y métricas de desempeño, y cuando presentaba intervención, se exigió que describiera el componente de acción y el desenlace evaluado.

**Tabla 1.***Términos por base de datos*

Base de datos	Filtros	Cadena de búsqueda en inglés	Cadena de búsqueda en español
SCOPUS	TITLE-ABS-KEY, años 2020–2025, educación superior	("higher education" OR university) AND (dropout OR attrition OR retention) AND ("learning analytics" OR "educational data mining" OR "machine learning" OR "artificial intelligence" OR "early warning") AND (intervention OR feedback OR mentoring OR "student support")	(educación superior OR universidad) AND (deserción OR abandono OR retención) AND ("analítica de aprendizaje" OR "minería de datos educativa" OR "aprendizaje automático" OR "inteligencia artificial" OR "alerta temprana") AND (intervención OR retroalimentación OR tutoría OR acompañamiento)
Web of Science	Topic, años 2020–2025, refinamiento por categoría Educación	("learning analytics") AND (dashboard OR visualization OR "actionable insights" OR "self-regulation") AND ("higher education" OR university)	("analítica de aprendizaje") AND (tablero OR panel OR visualización OR "insights accionables" OR autorregulación) AND (educación superior OR universidad)
SciELO	Relevancia, años 2020–2025, texto completo cuando disponible	("higher education" OR university) AND (access OR admission OR barriers OR equity) AND (Ecuador OR "Latin America")	(acceso OR ingreso OR admisión) AND (barreras OR brechas OR equidad) AND (educación superior OR universidad) AND (Ecuador OR Esmeraldas)
Google Académico	Años 2020–2025, orden por relevancia, verificación manual de texto completo y DOI	("student dropout" OR "student retention") AND ("machine learning" OR "predictive model" OR "early warning system") AND (higher education)	(deserción estudiantil OR retención estudiantil) AND (modelo predictivo OR "sistema de alerta temprana" OR "aprendizaje automático") AND (educación superior)
Complementaria, ética y equidad (todas las bases)	Años 2020–2025, términos éticos y de sesgo	("learning analytics" OR "student prediction") AND (privacy OR ethics OR fairness OR bias OR explainability OR interpretable)	("analítica de aprendizaje" OR predicción académica) AND (privacidad OR ética OR equidad OR sesgo OR explicabilidad OR interpretable)



---

## Resultados

### Caracterización de los estudios incluidos

En el conjunto de evidencias se identificaron aproximaciones complementarias para comprender y actuar sobre la deserción y la permanencia, con predominio de diseños aplicados que integran analítica de aprendizaje, minería de datos educativa, y evaluación de respuestas estudiantiles frente a alertas institucionales, en virtud de que la retención suele depender de señales tempranas, de la calidad del acompañamiento, y de la capacidad institucional para traducir datos en acciones concretas, en este marco se observan estudios centrados en predicción con métricas comparables como AUC y F1, y estudios centrados en mecanismos de apoyo que miden cambios conductuales y formas de interacción con docentes o servicios de apoyo, lo cual permite triangular desempeño algorítmico con viabilidad de implementación y aceptación estudiantil (Kabathova & Drlik, 2021; Imundo et al., 2025).

Asimismo, se incorporan evidencias con énfasis en barreras de ingreso y desigualdades asociadas a condiciones socioeconómicas, y también trabajos que priorizan el uso de datos pre-matrícula para identificar vulnerabilidad desde el inicio, cabe resaltar que este enfoque resulta especialmente pertinente cuando la institución requiere estrategias de retención en cohortes con heterogeneidad marcada, ya que permite combinar señales de acceso, apoyos financieros y responsabilidades extraacadémicas, con mecanismos de seguimiento y acompañamiento durante el semestre, por consiguiente la literatura revisada ofrece insumos para articular políticas de ingreso con modelos predictivos y rutas de intervención (Rodas et al., 2023; Carballo-Mendivil et al., 2025).

**Tabla 2.**
*Características de los estudios incluidos*

<i>Estudio</i>	<i>Población</i>	<i>Tipo de datos</i>	<i>Enfoque</i>	<i>Resultado principal reportado</i>
<i>Bañeres et al., 2023</i>	Curso en línea, pilotos por actividades evaluables	Clickstream + desempeño + perfil	Alerta temprana + mensajes de intervención	Menor deserción y mayor engagement tras intervención
<i>Essel et al., 2022</i>	68 universitarios, 34 experimental y 34 control	Prueba de logro + participación	Chatbot como asistente docente	Mejora académica mayor con chatbot
<i>Kabathova &amp; Drlik, 2021</i>	261 estudiantes en Moodle	Logs + puntajes parciales	Comparación ML	RF/LR con alto desempeño predictivo
<i>Carballo-Méndivil et al., 2025</i>	~40.000 ingresantes 2014–2024	Datos de matrícula	XGBoost “día uno”	AUC/F1 moderados, sensibilidad alta
<i>Imundo et al., 2025</i>	356 universitarios (encuesta)	Reportes de alerta + respuestas	Experiencia y respuesta a alertas	Cambios conductuales y contactos de apoyo
<i>Rebelo Marcolino et al., 2025</i>	Moodle, ventanas semanales	Logs Moodle	Optimización ML	F1 sube con avance del curso
<i>Liu et al., 2025</i>	Dataset con variables académicas y no académicas	Tabular, distillation/síntesis	Privacidad + interpretabilidad	AUC alto con datos completos, caída al excluir desempeño
<i>Romero &amp; Liao, 2025</i>	4.424 registros (Portugal)	Académico + socioeconómico	ML + efecto de beca (PSM)	XGBoost con F1 alto, beca reduce odds de deserción
<i>Villar &amp; Andrade, 2024</i>	Comparación de algoritmos supervisados	Tabular institucional	Benchmark ML	Boosting con F1 alto, AUC > 0,9 en mejores modelos
<i>Rodas et al., 2023</i>	Caso Ecuador (UNAE)	Series y perfiles socioeconómicos	Admisión y retención	Retención alta, brechas por quintil de pobreza

**Desempeño de modelos predictivos para riesgo de deserción**

En modelos construidos con trazas de LMS y desempeño parcial, se observa rendimiento alto cuando existe señal académica suficiente y continuidad de registros, en un caso con Moodle y 261 estudiantes, Random Forest alcanzó accuracy 0,93, recall 0,96, F1 0,91 y AUC 0,968, mientras que regresión logística mostró accuracy 0,93, recall 0,98, F1 0,90 y AUC 0,924, y en una comparación adicional de algoritmos supervisados se reportaron F1 de 0,90 para Random Forest, y valores superiores para boosting, con LightGBM en 0,96 y CatBoost en 0,95, además de AUC superiores a 0,9 en los mejores modelos, cabe resaltar que esta convergencia sugiere que el rendimiento no depende únicamente del algoritmo, sino de la calidad de variables y del momento del semestre en que se predice (Kabathova & Drlik, 2021; Villar & Andrade, 2024).



Cuando el objetivo es predecir “desde el día uno” usando únicamente datos de matrícula, el desempeño tiende a moderarse, aunque mejora la utilidad operativa por anticipación, en un estudio con casi 40.000 ingresantes y XGBoost entrenado con variables académicas previas, socioeconómicas, demográficas y perceptuales, se reportó AUC-ROC 0,6902, F1 para la clase deserción 0,6946 y sensibilidad 88%, identificando además que 59% de estudiantes podían clasificarse como alto riesgo con variabilidad por programa, en paralelo, al trabajar con ventanas temporales semanales en logs Moodle, el desempeño evoluciona conforme aumenta la evidencia conductual, con CatBoost pasando de F1 0,40 en semana 1 a 0,97 en semana 7, lo cual es consistente con una lógica de predicción progresiva orientada a intervención por etapas (Carballo-Mendivil et al., 2025; Rebelo Marcolino et al., 2025).

En el plano de interpretabilidad, privacidad y determinantes institucionales accionables, se reporta que el rendimiento se maximiza con variables académicas de desempeño, y se debilita al excluirlas, en un análisis con múltiples sub-datasets se indica que la AUC de Random Forest puede alcanzar 0,957 con información completa, y que, al usar distillation con LightGBM, con 100 muestras sintetizadas se logra AUC aproximada de 0,876, además se muestra que métodos de síntesis como CGAN con tamaños bajos pueden aproximarse a AUC ~0,5, por consiguiente la gobernanza de datos debe equilibrar privacidad con suficiencia predictiva, complementariamente, en un estudio con 4.424 registros se reportó F1 0,904 para XGBoost, y un efecto asociado a becas con reducción de las odds de deserción cercana a 40% y reducción de probabilidad de 22,2% manteniendo constantes otras variables, lo cual perfila la beca como palanca de retención con lectura causal aproximada (Liu et al., 2025; Romero & Liao, 2025).

### **Estrategias innovadoras de intervención y retención asociadas a analítica y alertas**

En intervenciones acopladas a sistemas de alerta temprana en entornos en línea, se documenta que la identificación de riesgo y el envío de mensajes con metas de corto plazo pueden modificar el engagement de grupos inicialmente clasificados como “falsos positivos”, elevando su tiempo de acceso y acercándolo a perfiles activos, y además se reporta una disminución significativa de la deserción en participantes, con una diferencia relevante de 12% frente a no participantes al final del curso y una diferencia de 5% respecto a un semestre previo con mecanismos más limitados, en virtud de que la intervención temprana opera como recordatorio estructurado y orientación práctica, en un plano complementario de alertas institucionales, estudiantes reportan cambios conductuales

posteriores a recibir alertas, lo cual sugiere que la eficacia no depende solo del algoritmo, sino de su integración con comunicación, claridad y rutas de apoyo (Bañeres et al., 2023; Imundo et al., 2025).

Desde una perspectiva de soporte mediado por IA conversacional, un diseño pretest–posttest con asignación a grupo experimental y control evidenció incremento mayor del rendimiento académico cuando se incorporó un chatbot, con medias pretest 40,6 (DE 4,95) y posttest 81,1 (DE 3,19) en el grupo chatbot, frente a 43,4 (DE 4,09) y 65,2 (DE 3,73) en el grupo control, además se reportó interacción significativa  $F(1,66)=87,5$ ,  $p<0,05$ , con eta parcial cuadrada 0,57, y una ganancia diferencial aproximada de 18,7 puntos en la mejora pre–post entre grupos, cabe resaltar que este tipo de soporte puede funcionar como estrategia de retención indirecta al fortalecer desempeño y reducir fricción comunicativa, en paralelo, encuestas de experiencia con alertas muestran que 63,6% de estudiantes cambió su conducta tras recibir una alerta, y que el contacto con docente/TA fue más frecuente que con asesoría, lo cual orienta ajustes de diseño para aumentar la conexión efectiva con servicios institucionales (Essel et al., 2022; Imundo et al., 2025).

### **Evidencia sobre acceso, apoyo financiero y permanencia en Ecuador**

En evidencia aplicada al contexto ecuatoriano, se reporta retención institucional de 96,98% en el caso analizado, con referencias comparativas de promedio nacional 73,6% y promedio en universidades públicas 82,71%, además se señala que más de 90% de estudiantes pertenecen a los dos quintiles de menor pobreza, lo cual sugiere que la permanencia se encuentra mediada por composición socioeconómica y por políticas institucionales de acompañamiento, por consiguiente, para una universidad pública territorial como la Universidad Técnica Luis Vargas Torres de Esmeraldas, la integración de modelos predictivos con estrategias de acceso y permanencia debe priorizar variables de vulnerabilidad y apoyos económicos, y operacionalizar rutas de intervención que combinen seguimiento académico, comunicación oportuna y servicios de bienestar, articulando datos de matrícula, señales de LMS y mecanismos de becas o alivios financieros como componentes del mismo sistema de retención (Rodas et al., 2023; Romero & Liao, 2025).

---

## Discusión

La discusión sobre retención estudiantil basada en datos tiende a consolidarse cuando la institución reconoce que el compromiso académico no es un marcador único, sino un constructo compuesto por conductas observables, experiencias subjetivas y condiciones contextuales, en virtud de que la interacción registrada en plataformas puede reflejar esfuerzo, pero también puede expresar obligación, ansiedad o estrategias instrumentales, por consiguiente, la interpretación de señales debe evitar reduccionismos, especialmente en universidades públicas con heterogeneidad social, cabe resaltar que la síntesis sobre engagement en learning analytics ha insistido en la necesidad de conceptualizaciones más finas y coherentes entre estudios, y a la vez, las prácticas institucionales documentadas en estudios de caso muestran que el valor no emerge solo de tener analítica, sino de definir propósitos claros, equipos responsables y beneficios verificables para estudiantes y docentes, lo cual orienta a la Universidad Técnica Luis Vargas Torres de Esmeraldas a no adoptar modelos por moda, sino a construir un marco institucional donde engagement, riesgo y apoyo sean operacionalizaciones transparentes y situadas (Bergdahl et al., 2024; Dixon et al., 2025).

En relación con la predicción de riesgo y la intervención temprana, la evidencia reciente apunta a que los esquemas más prometedores son aquellos que integran identificación temprana con retroalimentación y acompañamiento, ya que la alerta aislada puede producir ruido institucional, fatiga del estudiante o respuestas defensivas, en virtud de que la señal de riesgo se vuelve útil cuando activa una acción concreta, breve y pertinente, por consiguiente, los enfoques centrados en early identification con feedback e intervención sugieren una lógica de circuito cerrado, donde predicción, comunicación y seguimiento se ajustan en ciclos y no como implementación estática, cabe resaltar que también se han descrito intervenciones basadas en evidencia aplicadas a cursos específicos, lo cual refuerza que el efecto se maximiza cuando la intervención se diseña para una tarea, un curso o un grupo con necesidades reconocibles, y no como un mensaje genérico de “mejora tu desempeño”, en el caso de Esmeraldas, esto se traduce en priorizar intervenciones de alto impacto y baja fricción en primer ciclo, nivelación, tutorías focalizadas y microacciones de autorregulación, integradas a un sistema de alerta que se mida por su efectividad y por su cobertura real (Dai et al., 2025; Utamachant et al., 2023).

Un componente que atraviesa la discusión es la capacidad de convertir datos en decisiones comprensibles para el estudiante, donde los tableros y visualizaciones de learning analytics se



proponen como herramientas para transformar registros en recomendaciones accionables, en virtud de que la retención requiere agencia del estudiante y no solo vigilancia institucional, por consiguiente, la discusión sobre dashboards destaca que la utilidad depende de su diseño, del tipo de indicador, de la claridad del mensaje y del acoplamiento con estrategias de apoyo, cabe resaltar que la evaluación de tableros orientados a autorregulación ha puesto énfasis en que la medición debe sostener cambios en comportamiento de estudio, y no únicamente aumentar la cantidad de accesos, lo cual es particularmente relevante para una institución que busca retener sin aumentar inequidades, ya que un tablero que asume conectividad estable o disponibilidad de tiempo puede penalizar a estudiantes que trabajan o que viven con limitaciones tecnológicas, y por consiguiente, el diseño en la UT Luis Vargas Torres debería incorporar indicadores sensibles a la realidad local, y acompañarse de rutas claras de tutoría y apoyo, evitando soluciones que se reduzcan a “mostrar datos” sin intervención pedagógica (Susnjak et al., 2022; de Vreugd et al., 2024).

La expansión de sistemas predictivos y de seguimiento abre una discusión inevitable sobre privacidad, ética y confianza, en virtud de que el procesamiento de datos académicos y de comportamiento puede percibirse como intrusivo si no existe transparencia, consentimiento informado y reglas explícitas de uso, por consiguiente, las propuestas centradas en privacidad en learning analytics subrayan que la mejora de práctica exige comprender riesgos, límites y responsabilidades institucionales, y de manera complementaria, las percepciones estudiantiles sobre la ética de la analítica sugieren que la aceptación no se logra solo con “buenas intenciones”, sino con explicaciones claras, posibilidad de objeción, y garantías de no estigmatización, cabe resaltar que esto impacta directamente la retención, porque un sistema de alerta que erosionara confianza podría deteriorar engagement y disposición a buscar ayuda, y por consiguiente, para la UT Luis Vargas Torres se vuelve prioritario formalizar gobernanza de datos, definir qué variables se usan, por qué se usan, quién accede a resultados, cómo se almacenan, y cómo se evita que el “riesgo” se convierta en etiqueta fija (Viberg et al., 2022; Jagačić et al., 2024).

Otro eje central es la equidad algorítmica y la justicia distributiva de las intervenciones, en virtud de que un modelo puede mejorar métricas globales y aun así producir decisiones injustas en subgrupos, por consiguiente, la discusión sobre fairness en predicción académica plantea que explicar y asegurar equidad exige evaluar sesgos, comparar errores por subpoblación, y evitar que variables proxy reproduzcan desigualdades, esto dialoga de forma directa con estrategias de permanencia basadas en apoyos financieros, ya que el financiamiento puede ser una palanca real



de retención y desempeño, cabe resaltar que la evidencia sobre becas y rendimiento académico sugiere que el apoyo económico tiene efectos medibles, y por consiguiente, en un contexto como Esmeraldas, donde el costo de oportunidad y la precariedad pueden ser determinantes, la implementación institucional debería combinar modelos de riesgo con rutas explícitas de apoyo financiero y bienestar, no solo con tutorías, además de auditar sistemáticamente si el sistema de alerta beneficia por igual a quienes enfrentan mayores barreras de ingreso (Kesgin et al., 2025; Berlanga & Corti, 2025).

En síntesis, la discusión converge en una idea operativa, la retención efectiva requiere una arquitectura socio-técnica donde predicción, intervención, ética y equidad funcionen como un solo sistema, en virtud de que la precisión del modelo no compensa ausencia de intervención, y la intervención sin legitimidad ética puede fracasar por falta de confianza, por consiguiente, para la Universidad Técnica Luis Vargas Torres de Esmeraldas la ruta más pertinente consiste en implementar por fases, primero un diagnóstico de barreras de ingreso y un conjunto mínimo de variables con gobernanza clara, luego un sistema de alerta temprano con explicabilidad y auditoría por subgrupos, y en paralelo un portafolio de intervenciones escalables, tutorías de primer ciclo, apoyos académicos por asignatura crítica, acompañamiento psicosocial, y criterios transparentes de derivación a becas o ayudas, cabe resaltar que el valor científico de la propuesta se fortalece cuando cada fase se evalúa con indicadores de permanencia y con mediciones de efecto, documentando qué intervención funciona para qué perfil estudiantil, y por consiguiente, la discusión respalda un enfoque aplicado y contextualizado, capaz de integrar analítica con justicia educativa y con sostenibilidad institucional.

---

## Conclusiones

Los hallazgos integrados confirman que la retención estudiantil en educación superior no puede tratarse como un resultado aislado del desempeño académico, sino como una consecuencia de trayectorias condicionadas por barreras de ingreso, vulnerabilidades socioeconómicas y necesidades de acompañamiento temprano, por consiguiente, la evidencia revisada respalda que una universidad que busca reducir abandono debe intervenir desde el inicio con acciones concretas y medibles, y no esperar a que el riesgo se materialice al final del semestre, en esa lógica, los modelos predictivos muestran utilidad práctica cuando se combinan con datos de matrícula y con señales de actividad y desempeño en plataformas, donde la predicción “día uno” aporta anticipación con un desempeño moderado, mientras que la predicción basada en ventanas semanales incrementa su precisión conforme se acumula evidencia conductual, lo cual sugiere que el enfoque más operativo no es un único modelo estático, sino un esquema progresivo de alertas por etapas, que inicia con variables disponibles al ingreso y se fortalece con información académica temprana, además, los resultados empíricos sustentan que la retención mejora cuando la alerta se acopla a intervención, ya sea mediante mensajes estructurados, tutorías o apoyos focalizados, y cuando se incorporan soportes tecnológicos como asistentes virtuales que reducen fricción y mejoran rendimiento, de modo que la innovación relevante no es únicamente el algoritmo, sino la capacidad institucional para transformar predicciones en acompañamiento efectivo, oportuno y persistente

En el contexto de la Universidad Técnica Luis Vargas Torres de Esmeraldas, las conclusiones orientan a construir una arquitectura socio-técnica de permanencia que integre diagnóstico de ingreso, predicción, intervención, y evaluación, en virtud de que la precisión del modelo por sí sola no garantiza permanencia si no existe un circuito claro de acción, con responsables, umbrales, protocolos de contacto y seguimiento, por consiguiente, la implementación más pertinente es por fases, primero una caracterización de barreras y condiciones de ingreso que permita identificar perfiles de vulnerabilidad, luego un sistema de alerta temprana con explicabilidad, que priorice casos y ofrezca razones comprensibles para orientar tutorías, nivelación y acompañamiento, y posteriormente un portafolio de intervenciones escalables, con acciones de baja fricción y alta cobertura en el primer ciclo, reforzadas por rutas de apoyo académico, bienestar y soporte financiero cuando corresponda, cabe resaltar que la evidencia también obliga a incorporar





gobernanza de datos, privacidad, ética y equidad algorítmica como condiciones de legitimidad, dado que un sistema que estigmatice o que opere sin transparencia puede deteriorar confianza y terminar afectando la misma retención que busca mejorar, por consiguiente, la evaluación debe considerar desempeño global y también desempeño por subgrupos, errores diferenciales, acceso real a intervenciones y beneficios efectivos para quienes enfrentan mayores barreras

Finalmente, se concluye que la ruta institucional con mayor potencial es aquella que conecta predicción con intervención y con una medición continua de resultados, de modo que cada decisión se sostenga en indicadores trazables, retención por cohorte, cambios en rendimiento, respuesta a alertas, y estimaciones de efecto cuando sea posible, además de un monitoreo de estabilidad del modelo para evitar deriva entre periodos académicos, por consiguiente, la contribución aplicada para Esmeraldas se expresa en un modelo de gestión que combina, i) identificación temprana y progresiva del riesgo, ii) intervenciones personalizadas y evaluables, iii) herramientas de autorregulación y comunicación que entreguen recomendaciones accionables, y iv) criterios de equidad y transparencia que protejan derechos y fortalezcan la confianza estudiantil, en virtud de ello, futuras implementaciones deberían priorizar pilotos controlados en carreras o asignaturas críticas, documentar qué intervención funciona para qué perfil estudiantil, y escalar únicamente aquello que demuestre mejoras consistentes en permanencia y desempeño, manteniendo siempre la coherencia entre datos, decisiones y acompañamiento real.



---

## Referencias bibliográficas

- Bañeres, D., Rodríguez-González, M. E., Guerrero-Roldán, A.-E., & Cortadas, P. (2023). An early warning system to identify and intervene online dropout learners. *International Journal of Educational Technology in Higher Education*, 20, Article 3. <https://doi.org/10.1186/s41239-022-00371-5>
- Bergdahl, N., Bond, M., Sjöberg, J., Dougherty, M., & Oxley, E. (2024). Unpacking student engagement in higher education learning analytics: A systematic review. *International Journal of Educational Technology in Higher Education*, 21, Article 63. <https://doi.org/10.1186/s41239-024-00493-y>
- Berlanga, V., & Corti, F. (2025). Impact of scholarships on university academic performance: A comparative analysis of students with and without scholarships. *Frontiers in Education*, 10, 1554073. <https://doi.org/10.3389/feduc.2025.1554073>
- Carballo-Mendivil, B., Arellano-González, A., Ríos-Vázquez, N. J., & Lizardi-Duarte, M. P. (2025). Predicting student dropout from day one: XGBoost-based early warning system for higher education institutions. *Applied Sciences*, 15(16), 9202. <https://doi.org/10.3390/app15169202>
- Chang, Y.-H., Chang, W.-H., & Chang, C.-Y. (2025). Developing an early warning system for at-risk students in higher education with tailored interventions. *Education Sciences*, 15(10), 1321. <https://doi.org/10.3390/educsci15101321>
- Dai, W., Lin, J., Jin, F. J.-Y., Tsai, Y.-S., Srivastava, N., Le Bodic, P., Gašević, D., & Chen, G. (2025). Learning analytics for early identification of at-risk students and feedback intervention. *Journal of Learning Analytics*, 12(3), 102–125. <https://doi.org/10.18608/jla.2025.8735>
- de Oliveira, C. F., Sobral, S. R., Ferreira, M. J., & Moreira, F. (2021). How does learning analytics contribute to prevent students' dropout in higher education: A systematic literature review. *Big Data and Cognitive Computing*, 5(4), 64. <https://doi.org/10.3390/bdcc5040064>
- de Vreugd, L., van Leeuwen, A., Jansen, R., & van der Schaaf, M. (2024). Learning analytics dashboard design and evaluation to support student self-regulation of study behaviour. *Journal of Learning Analytics*, 11(3), 249–262. <https://doi.org/10.18608/jla.2024.8529>
- Dixon, E., Howe, H., & Richter, S. (2025). Exploring learning analytics practices and their benefits through the lens of three case studies in UK higher education. *Research in Learning Technology*, 33, 3127. <https://doi.org/10.25304/rlt.v33.3127>



- Essel, H. B., Vlachopoulos, D., Tachie-Menson, A., Johnson, E. E., & Baah, P. K. (2022). The impact of a virtual teaching assistant (chatbot) on students' learning in Ghanaian higher education. *International Journal of Educational Technology in Higher Education*, 19, Article 57. <https://doi.org/10.1186/s41239-022-00362-6>
- Guzmán-Valenzuela, C., Gómez-González, C., Rojas-Murphy Tagle, A., et al. (2021). Learning analytics in higher education: A preponderance of analytics but very little learning? *International Journal of Educational Technology in Higher Education*, 18, 23. <https://doi.org/10.1186/s41239-021-00258-x>
- Ifenthaler, D., & Yau, J. Y.-K. (2020). Utilising learning analytics to support study success in higher education: A systematic review. *Educational Technology Research and Development*, 68, 1961–1990. <https://doi.org/10.1007/s11423-020-09788-z>
- Imundo, C., Ferrante, L., De Iulio, C., & Blasi, C. (2025). Student knowledge of and responses to an early alert system: An assessment for improvement. *Applied Sciences*, 15(11), 6316. <https://doi.org/10.3390/app15116316>
- Jagačić, T., Dragičević, N., & Drljača, N. (2024). Students' perceptions of the ethical aspects of learning analytics. *TEM Journal*, 13(4), 3526–3535. <https://doi.org/10.18421/TEM134-85>
- Kabathova, J., & Drlik, M. (2021). Towards educational data mining: Predicting student dropout in university courses using different machine learning techniques. *Applied Sciences*, 11(7), 3130. <https://doi.org/10.3390/app11073130>
- Kesgin, K., Kiraz, S., Kosunalp, S., & Stoycheva, B. (2025). Beyond performance: Explaining and ensuring fairness in student academic performance prediction with machine learning. *Applied Sciences*, 15(15), 8409. <https://doi.org/10.3390/app15158409>
- Linden, C. (2022). Engagement with targeted support and student retention: Evidence from an early intervention. *Student Success*, 13(1), 67–73. <https://doi.org/10.5204/ssj.2152>
- Liu, H., et al. (2025). Model interpretability on private-safe oriented student dropout risk prediction in higher education. *PLOS ONE*, 20(2), e0317726. <https://doi.org/10.1371/journal.pone.0317726>
- Liu, Y., Wang, W., & Xu, E. (2025). The effectiveness of learning analytics-based interventions in enhancing students' learning effect: A meta-analysis of empirical studies. *SAGE Open*, 15(2), 21582440251336707. <https://doi.org/10.1177/21582440251336707>



- Logroño, P. F. B. (2025). Acceso a la educación superior en Ecuador: una deuda de la administración pública. *Perspectivas Sociales y Administrativas*, 3(2), 56–66. <https://doi.org/10.61347/psa.v3i2.93>
- Mustofa, S., Emon, Y. R., Mamun, S. B., et al. (2025). A novel AI-driven model for student dropout risk analysis with explainable AI insights. *Computers and Education: Artificial Intelligence*, 8, 100352. <https://doi.org/10.1016/j.caeai.2024.100352>
- Rebelo Marcolino, M., Reis Porto, T., Thompsen Primo, T., Targino, R., Ramos, V., Marques Queiroga, E., Munoz, R., & Cechinel, C. (2025). Student dropout prediction through machine learning optimization: Insights from Moodle log data. *Scientific Reports*, 15, Article 9840. <https://doi.org/10.1038/s41598-025-93918-1>
- Rodas, M. P., Gomez, A. H., & Stefos, E. (2023). La admisión y retención universitaria: caso ecuatoriano en la Universidad Nacional de Educación. *Revista de la Educación Superior*, 52(208). <https://doi.org/10.36857/resu.2023.208.2656>
- Romero, S., et al. (2025). Statistical and machine learning models for predicting students' dropout risk: The effect of scholarship programs. *PLOS ONE*, 20(6), e0325047. <https://doi.org/10.1371/journal.pone.0325047>
- Shafiq, D. A., Marjani, M., Habeeb, R. A. A., & Asirvatham, D. (2022). Student retention using educational data mining and predictive analytics: A systematic literature review. *IEEE Access*, 10. <https://doi.org/10.1109/ACCESS.2022.3188767>
- Silva-Martínez, G., Iglesias-Martínez, M. J., & Lozano-Cabezas, I. (2023). A qualitative study on barriers in learning opportunities in Ecuadorian higher education. *Societies*, 13(3), 56. <https://doi.org/10.3390/soc13030056>
- Susnjak, T., Ramaswami, G. S., & Mathrani, A. (2022). Learning analytics dashboard: A tool for providing actionable insights to learners. *International Journal of Educational Technology in Higher Education*, 19, Article 12. <https://doi.org/10.1186/s41239-021-00313-7>
- Utamachant, P., Anutariya, C., & Pongnumkul, S. (2023). i-Ntervene: Applying an evidence-based learning analytics intervention to support computer programming instruction. *Smart Learning Environments*, 10, Article 37. <https://doi.org/10.1186/s40561-023-00257-7>
- Viberg, O., Mutimukwe, C., & Grönlund, Å. (2022). Privacy in learning analytics research: Understanding the field to improve practice. *Journal of Learning Analytics*, 9(3), 169–182. <https://doi.org/10.18608/jla.2022.7751>



---

Villar, R., & Andrade, R. (2024). Student dropout prediction: A comparative study of supervised machine learning algorithms. *Discover Artificial Intelligence*, 4, Article 15.  
<https://doi.org/10.1007/s44163-023-00079-z>

**Conflicto de intereses:**

Los autores declaran que no existe conflicto de interés posible.

**Financiamiento:**

No existió asistencia financiera de partes externas al presente artículo.

**Agradecimiento:**

N/A

**Nota:**

El artículo no es producto de una publicación anterior.