

UNEMI

UNIVERSIDAD ESTATAL DE MILAGRO

REPÚBLICA DEL ECUADOR

UNIVERSIDAD ESTATAL DE MILAGRO
FACULTAD DE POSGRADO

VICERRECTORADO DE INVESTIGACIÓN Y POSGRADO

ARTÍCULOS PROFESIONALES DE ALTO NIVEL
PREVIO A LA OBTENCIÓN DEL TÍTULO DE:

MAGÍSTER EN INTELIGENCIA ARTIFICIAL PARA LA EDUCACIÓN

TEMA:

LEARNING ANALYTICS SYSTEMS BASADO EN INTELIGENCIA ARTIFICIAL
COMO PREDICTORES DE DESERCIÓN EN BACHILLERATO TÉCNICO EN
INFORMÁTICA

Autor:

RONQUILLO MURRIETA ROXANA MARIELLA
CAIZA CRIOLLO SILVIA VERONICA
AGUIRRE REVELO MARTHA CECILIA

Director:

MOREIRA CHOEZ JENNIFFER SOBEIDA

Milagro, año 2026

Learning Analytics Systems basado en inteligencia artificial como predictores de deserción en Bachillerato Técnico en Informática

doi.org/10.33386/593dp.2026.2.3932

Silvia Verónica Caiza-Criollo*

Martha Cecilia Aguirre-Revelo**

Roxana Mariella Ronquillo-Murrieta***

Jennifer Sobeida Moreira-Choez****

Resumen

La deserción escolar en la educación técnica constituye un desafío estructural que compromete la equidad, la eficiencia interna y la calidad de los sistemas educativos, especialmente en contextos donde convergen factores académicos, tecnológicos y motivacionales. En este marco, el presente estudio se orienta en predecir la deserción escolar mediante Learning Analytics Systems basados en inteligencia artificial en bachillerato técnico en informática en la Unidad Educativa Patrimonio de la Humanidad. Se adoptó un enfoque cuantitativo, con diseño no experimental y transversal, de nivel descriptivo–predictivo. La muestra estuvo conformada por 125 estudiantes. Se aplicó un cuestionario estructurado mediante Google Forms, con adecuados índices de confiabilidad, y los datos fueron procesados en IBM SPSS mediante análisis descriptivos, correlacionales y regresión lineal múltiple. Los resultados evidencian que el rendimiento académico, la participación y compromiso, el uso de tecnologías educativas, los factores personales y motivacionales y el apoyo institucional percibido predicen significativamente la deserción, con efectos negativos sobre el riesgo de abandono. Se concluye que los sistemas de analítica de aprendizaje constituyen herramientas válidas para la identificación temprana de estudiantes en riesgo y para la toma de decisiones educativas basadas en datos.

Palabras clave: analítica del aprendizaje; deserción escolar; inteligencia artificial; educación técnica; abandono escolar.

* Estudiante de la Maestría en Inteligencia Artificial para la Educación en la Universidad Estatal de Milagro. Universidad Estatal de Milagro. E-mail: scaizac3@unemi.edu.ec. ORCID: <https://orcid.org/0009-0009-1098-2793>. (Autor de Correspondencia)

** Estudiante de la Maestría en Inteligencia Artificial para la Educación en la Universidad Estatal de Milagro. Universidad Estatal de Milagro. E-mail: maguirrer5@unemi.edu.ec.

*** Estudiante de la Maestría en Inteligencia Artificial para la Educación en la Universidad Estatal de Milagro. Universidad Estatal de Milagro. E-mail: rronquillom6@unemi.edu.ec. ORCID: <https://orcid.org/0009-0003-6318-3414>.

**** Docente de la Facultad de Posgrado de la Universidad Estatal de Milagro. Universidad Estatal de Milagro. E-mail: jmoreirac10@unemi.edu.ec. ORCID: <https://orcid.org/0000-0001-8604-3295>.

Artificial intelligence–based learning analytics systems as predictors of dropout in technical high school in computer science

Abstract

School dropout in technical education represents a structural challenge that affects equity, internal efficiency, and the overall quality of educational systems, particularly in contexts where academic, technological, and motivational factors converge. Within this framework, the present study aims to predict school dropout through Artificial Intelligence–based Learning Analytics Systems in a Technical High School in Computer Science at Unidad Educativa Patrimonio de la Humanidad. A quantitative approach was adopted, with a non-experimental, cross-sectional design at a descriptive–predictive level. The sample consisted of 125 students. A structured questionnaire was administered via Google Forms, demonstrating adequate reliability indices, and data were processed using IBM SPSS through descriptive, correlational, and multiple linear regression analyses. The findings indicate that academic performance, participation and engagement, use of educational technologies, personal and motivational factors, and perceived institutional support significantly predict dropout, showing negative effects on the risk of withdrawal. It is concluded that learning analytics systems constitute valid tools for the early identification of at-risk students and for data-driven educational decision-making.

Keywords: learning analytics; school dropout; artificial intelligence; technical education; school attrition.

Introducción

La deserción escolar constituye uno de los principales desafíos de los sistemas educativos contemporáneos, particularmente en contextos de educación técnica, donde convergen factores académicos, socioeconómicos y tecnológicos (Barragán & Guzmán, 2025; Chari, 2024; Granata, 2022). En los últimos años, el avance de la analítica de datos educativos y la inteligencia artificial ha posibilitado el desarrollo de Learning Analytics Systems orientados a la predicción temprana del riesgo de abandono escolar (Córdova-Esparza et al., 2025; Wen & Nhu, 2025). Estos sistemas integran datos académicos, conductuales y contextuales con el propósito de generar modelos predictivos que faciliten la toma de decisiones institucionales y la implementación de intervenciones oportunas (Jayaram & Sundar, 2022). La literatura científica evidencia que el uso de modelos de aprendizaje automático incrementa la capacidad de anticipar trayectorias académicas desfavorables y fortalece las estrategias de retención educativa en distintos niveles formativos (Fierro et al., 2025; Moreira-Choez et al., 2025).

Diversos estudios han demostrado la eficacia de la inteligencia artificial aplicada a la educación para identificar patrones asociados al abandono escolar (Alamo, 2024; Paredes, 2024). Investigaciones desarrolladas en educación técnica secundaria han evidenciado que variables como la asistencia, el rendimiento académico y el nivel socioeconómico presentan una alta capacidad predictiva cuando se analizan mediante modelos de aprendizaje automático interpretables (Del Carpio-Mendoza, 2024). En este sentido, el uso de enfoques de Explainable Artificial Intelligence ha permitido mejorar la precisión de los modelos y aumentar la transparencia de los resultados, aspecto clave para su aceptación institucional y pedagógica (Choez & Miranda, 2024; Silva et al., 2025).

Por otra parte, investigaciones en educación superior y formación técnica han mostrado que los sistemas basados en inteligencia artificial contribuyen significativamente a la predicción del riesgo académico y la permanencia

estudiantil (Félix, 2025; Zambrana et al., 2026). Modelos sustentados en lógica difusa, redes neuronales y algoritmos de ensamble han alcanzado niveles de precisión superiores al 90 %, lo que confirma su potencial para anticipar fenómenos de deserción. Asimismo, estos estudios resaltan que la combinación de datos históricos y variables conductuales fortalece la capacidad de generalización de los modelos predictivos incluso en escenarios con conjuntos de datos reducidos (Bressane et al., 2022).

No obstante, la evidencia empírica revela problemáticas persistentes asociadas a la deserción escolar, reflejadas en resultados estadísticos preocupantes (Torres et al., 2026). En programas de educación técnica, se han reportado tasas de abandono superiores al 25 %, con valores que superan el 40 % en determinadas modalidades educativas. Modelos predictivos aplicados a grandes muestras estudiantiles han alcanzado niveles de recall cercanos al 85 %, lo que confirma la viabilidad técnica para identificar estudiantes en riesgo, pero también evidencia la magnitud estructural del problema de deserción escolar en este nivel educativo (Silva et al., 2025).

De manera adicional, estudios desarrollados en entornos virtuales han identificado relaciones estadísticamente significativas entre la participación estudiantil y la retención académica (Ademola, 2023; Ryan & Poole, 2019). Análisis longitudinales han demostrado que la disminución progresiva de la interacción en plataformas educativas se asocia con incrementos sustanciales en la probabilidad de abandono, con reducciones de retención superiores al 20 % en cursos con baja participación. Estos hallazgos refuerzan la necesidad de integrar métricas conductuales en los Learning Analytics Systems orientados a la predicción de la deserción escolar (Villegas-Ch et al., 2024).

A pesar de los avances reportados, persisten vacíos relevantes en la literatura científica. La mayoría de los estudios se concentra en educación superior o en contextos virtuales, mientras que la aplicación de Learning Analytics

Systems basados en inteligencia artificial en bachilleratos técnicos continúa siendo limitada (Caicedo et al., 2025). Además, se identifican carencias de estudios contextualizados a instituciones específicas, lo que restringe la transferencia de los modelos predictivos y su adaptación a realidades educativas locales, así como una limitada incorporación de enfoques interpretables en educación media técnica (López-Meneses et al., 2025).

En este contexto, resulta pertinente desarrollar investigaciones aplicadas a instituciones educativas concretas, como la Unidad Educativa Patrimonio de la Humanidad, donde el bachillerato técnico en informática enfrenta desafíos asociados al abandono escolar. La implementación de Learning Analytics Systems permite aprovechar los registros académicos y digitales existentes para construir modelos predictivos contextualizados, alineados con las necesidades institucionales y orientados a fortalecer la gestión educativa y la prevención temprana de la deserción (Fierro et al., 2025).

En atención a lo expuesto, el presente estudio se orienta a responder la siguiente pregunta de investigación: ¿Cómo predecir la deserción escolar mediante Learning Analytics Systems basados en inteligencia artificial en bachillerato técnico en informática en la Unidad Educativa Patrimonio de la Humanidad? En coherencia con esta interrogante, el objetivo general consiste en predecir la deserción escolar mediante Learning Analytics Systems basados en inteligencia artificial en bachillerato técnico en informática en la Unidad Educativa Patrimonio de la Humanidad, con el fin de aportar evidencia científica para el diseño de estrategias preventivas fundamentadas en datos.

Materiales y métodos

El estudio se estructuró bajo un enfoque cuantitativo, en la medida en que privilegia la medición objetiva de variables y el análisis sistemático de datos numéricos con el fin de identificar regularidades empíricas, asociaciones estadísticas y patrones subyacentes vinculados al fenómeno de la deserción escolar. Este enfoque

resulta especialmente pertinente cuando se pretende trascender la descripción superficial del problema y avanzar hacia la modelización analítica del riesgo de abandono, permitiendo estimar probabilidades y comportamientos futuros a partir de evidencia empírica. En este sentido, la integración de Learning Analytics Systems basados en inteligencia artificial no solo amplía la capacidad de procesamiento de grandes volúmenes de datos educativos, sino que introduce un nivel de sofisticación analítica que posibilita captar relaciones complejas, interacciones no lineales y estructuras latentes entre variables académicas, conductuales y contextuales. Por consiguiente, la aplicación de técnicas estadísticas junto con modelos predictivos contribuye a robustecer la validez interna del estudio, al tiempo que asegura criterios de objetividad, reproducibilidad y rigor en el tratamiento de la información.

En cuanto al tipo de investigación, se adoptó un enfoque aplicado, dado que el propósito central no se limitó a la generación de conocimiento teórico, sino que se orientó a la resolución de una problemática concreta y contextualizada en el ámbito educativo. Específicamente, la deserción escolar en el bachillerato técnico en informática constituye un fenómeno multifactorial con implicaciones directas en la trayectoria académica de los estudiantes y en la eficiencia del sistema educativo. Desde esta perspectiva, el carácter aplicado del estudio se justifica en la necesidad de producir evidencia empírica útil para la toma de decisiones institucionales, el diseño de estrategias de retención y la implementación de sistemas de alerta temprana sustentados en analítica de datos. De este modo, el conocimiento generado adquiere una dimensión operativa, orientada a la intervención y mejora de la práctica educativa.

Respecto al diseño de investigación, se optó por un diseño no experimental, en tanto las variables fueron analizadas sin manipulación deliberada, respetando su manifestación en el contexto natural en el que ocurren. Esta elección metodológica responde a la naturaleza del fenómeno estudiado, donde la intervención directa podría alterar las condiciones reales del

entorno educativo y comprometer la validez ecológica de los resultados. En consecuencia, el estudio se limitó a observar, registrar y analizar las variables tal como se presentan en la realidad institucional. Adicionalmente, se adoptó un diseño transversal, ya que la recolección de datos se realizó en un único momento temporal, lo que permitió obtener una representación sincrónica del fenómeno de estudio. Aunque este tipo de diseño no permite establecer relaciones causales definitivas, sí resulta adecuado para identificar asociaciones significativas, tendencias y configuraciones estructurales que sirven como base para modelos predictivos y estudios posteriores de carácter longitudinal.

Por su parte, el nivel de investigación se definió como descriptivo–predictivo, integrando dos niveles analíticos complementarios que fortalecen la comprensión del fenómeno. En primer lugar, el componente descriptivo permitió caracterizar de manera detallada las variables académicas, tecnológicas, conductuales y contextuales de la población estudiantil, proporcionando un panorama integral de las condiciones asociadas a la deserción escolar. Esta caracterización constituye un paso fundamental, ya que posibilita identificar perfiles de riesgo y segmentar la población en función de atributos relevantes. En segundo lugar, el componente predictivo implicó un nivel de análisis más avanzado, orientado a la estimación probabilística del riesgo de abandono mediante técnicas estadísticas e inferenciales. Este nivel no solo permite identificar relaciones entre variables, sino también anticipar comportamientos futuros, lo que resulta clave en la implementación de estrategias preventivas.

A continuación, se presenta la caracterización sociodemográfica de la muestra en la tabla 1, con el propósito de describir las condiciones personales, académicas y tecnológicas de los estudiantes del bachillerato técnico en informática. Esta información permite contextualizar los análisis posteriores vinculados a los sistemas de análisis de aprendizaje, garantizando una comprensión integral del entorno formativo en el que se desarrolla el estudio.

Tabla 1
Característica de la muestra los Sistemas de análisis de aprendizaje

Variable	Categoría	n	%
Edad	14–15 años	27	21,6
	16–17 años	85	68,0
	18 años o más	13	10,4
Sexo	Masculino	60	48,0
	Femenino	64	51,2
	Prefiere no decirlo	1	0,8
Nivel de bachillerato técnico en informática	Primero	38	30,4
	Segundo	30	24,0
	Tercero	57	45,6
Jornada de estudios	Matutina	125	100,0
Acceso a internet en el hogar	Sí	124	99,2
	No	1	0,8
Dispositivo tecnológico para actividades académicas	Teléfono móvil	48	38,4
	Computadora o laptop	29	23,2
	Computadora/laptop y teléfono móvil	45	36,0
	No dispone de dispositivo propio	3	2,4
Situación laboral actual	Solo estudia	107	85,6
	Estudia y trabaja	18	14,4

Nota. Elaboración propia con base en los datos obtenidos mediante cuestionario estructurado.

En la tabla 1 se evidencia la distribución de los estudiantes entre 16 y 17 años (68,0 %), con ligera mayoría femenina (51,2 %), lo que configura un grupo etario homogéneo propio del nivel medio superior. El mayor porcentaje cursa tercer año (45,6 %), lo que sugiere proximidad a la culminación del ciclo formativo. La totalidad asiste en jornada matutina y casi la totalidad dispone de acceso a internet en el hogar (99,2 %), condición favorable para la implementación de sistemas digitales de análisis de aprendizaje. No obstante, aunque el 74,4 % posee al menos un dispositivo tecnológico propio combinado o exclusivo, un 2,4 % carece de recursos, aspecto que podría incidir en brechas de participación académica.

La técnica de recolección de la información empleada fue la encuesta, seleccionada por su capacidad para recopilar datos de forma sistemática y estandarizada. Como instrumento se utilizó un cuestionario estructurado, diseñado para recolectar información relacionada con variables académicas,

tecnológicas y conductuales vinculadas al riesgo de deserción escolar. El instrumento fue elaborado con preguntas cerradas y escalas tipo Likert, lo que facilitó su posterior procesamiento estadístico. La aplicación del instrumento se realizó de manera digital mediante la plataforma Google Forms, lo que permitió optimizar el acceso, la organización y el almacenamiento de los datos. Previo a la aplicación del cuestionario, se presentó a los participantes un consentimiento informado, en el cual se explicó el propósito del estudio, la confidencialidad de la información y el uso exclusivamente académico de los datos, garantizando el cumplimiento de principios éticos en investigación educativa.

Con el propósito de evaluar la consistencia interna del instrumento aplicado, se estimó el coeficiente Alfa de Cronbach para cada dimensión y para el total de la escala como se muestra en la tabla 2. Este procedimiento permitió determinar la estabilidad y homogeneidad de los ítems que integran los sistemas de análisis de aprendizaje, asegurando la precisión de las mediciones obtenidas.

Tabla 2
Análisis de fiabilidad en los Sistemas de análisis de aprendizaje

Nº	Indicadores	Alfa de Cronbach	N de elementos
Dimensión1	Rendimiento Académico	0,703	4
Dimensión2	Participación y Compromiso Académico	0,721	4
Dimensión3	Uso de Tecnologías Educativas	0,879	4
Dimensión4	Factores Personales y Motivacionales	0,746	4
Dimensión5	Riesgo Percibido de Deserción Escolar	0,753	4
Dimensión6	Apoyo Institucional Percibido	0,852	4
Total		0,818	24

Nota. Elaboración propia a partir del procesamiento estadístico en SPSS.

Los resultados de la tabla 2 evidencian niveles de confiabilidad aceptables en todas las dimensiones, con coeficientes que oscilan entre 0,703 y 0,879, superando el umbral mínimo recomendado de 0,70 para investigaciones en

ciencias sociales. Destaca la dimensión Uso de Tecnologías Educativas ($\alpha = 0,879$) y Apoyo Institucional Percibido ($\alpha = 0,852$), lo que sugiere elevada homogeneidad interna en estos constructos. El coeficiente global de 0,818 confirma una consistencia interna robusta del instrumento en su conjunto, respaldando la estabilidad de las mediciones y la pertinencia de su aplicación para el análisis inferencial posterior.

Finalmente, el procesamiento y análisis de la información se efectuó mediante el software estadístico IBM SPSS. En una primera etapa se realizó el análisis descriptivo de los datos, a través de frecuencias, porcentajes y medidas de tendencia central. Posteriormente, se ejecutaron procedimientos analíticos orientados a identificar patrones y relaciones entre variables, generando insumos estadísticos que sirvieron como base para la construcción de modelos predictivos de deserción escolar mediante Learning Analytics Systems basados en inteligencia artificial.

Resultados y discusión

En este apartado se presentan los resultados obtenidos a partir del procesamiento estadístico de la información recolectada, organizados en función de los objetivos y dimensiones del estudio. Se exponen inicialmente los hallazgos descriptivos e inferenciales más relevantes y, de manera articulada, se contrastan con la literatura científica especializada. Este enfoque integrador permite no solo describir las tendencias observadas, sino también interpretar su alcance teórico y empírico dentro del campo de los sistemas de análisis de aprendizaje, fortaleciendo la validez argumentativa del estudio.

Para examinar la existencia de diferencias estadísticamente significativas en las dimensiones de los sistemas de análisis de aprendizaje según el sexo, se realizó una comparación de medias mediante la prueba t de Student para muestras independientes como se muestra en la tabla 3. Este procedimiento permitió identificar posibles variaciones en el comportamiento de los constructos evaluados,

considerando la distribución de puntajes y la magnitud de las diferencias observadas entre estudiantes masculinos y femeninos. Ver Tabla 3.

Los resultados expuestos en la Tabla 3. Comparación de medias por sexo en las dimensiones de los sistemas de análisis de aprendizaje mediante prueba t de Student para muestras independientes evidencian que no se registran diferencias estadísticamente significativas entre hombres y mujeres en la mayoría de las dimensiones evaluadas, dado que los valores de significancia superan el umbral crítico de $\alpha = 0,05$. Este comportamiento coincide con hallazgos recientes que reportan ausencia de efecto directo del sexo sobre indicadores académicos y abandono en contextos de educación superior, cuando se controlan variables de rendimiento y contexto institucional (Aparicio et al., 2025). Asimismo, investigaciones en deserción temprana señalan que el género tiende a actuar como variable moderadora condicionada por factores académicos y contextuales, más que como predictor autónomo (Suberviola, 2024). En este sentido, la homogeneidad observada sugiere que los sistemas de análisis de aprendizaje evaluados presentan estabilidad estructural respecto a esta variable demográfica.

Tabla 3

Diferencias de medias en las dimensiones de los sistemas de análisis de aprendizaje según sexo

Dimensiones	Sexo	N	M	DT	T	p
Rendimiento Académico	Masculino	61	15,85	2,39	0,206	0,838
	Femenino	64	15,77	2,33		
Participación y Compromiso Académico	Masculino	61	16,39	2,41	-0,340	0,735
	Femenino	64	16,55	2,64		
Uso de Tecnologías Educativas	Masculino	61	16,61	2,40	1,507	0,134
	Femenino	64	15,80	3,48		
Factores Personales y Motivacionales Masculino		61	17,59	2,01	1,080	0,282
Femenino		64	17,11	2,87		
Riesgo Percibido de Deserción Escolar	Masculino	61	8,67	3,77	-0,399	0,691
	Femenino	64	8,92	3,22		
Apoyo Institucional Percibido	Masculino	61	15,59	3,12	2,160	0,033
	Femenino	64	14,31	3,48		

No obstante, se identifica una diferencia significativa en la dimensión Apoyo Institucional Percibido ($p = 0,033$), donde los estudiantes masculinos reportan puntuaciones superiores. Este hallazgo puede interpretarse a la luz de estudios que muestran que el género modera la relación entre percepción de apoyo y desempeño académico en entornos digitales personalizados (Wongwatkit et al., 2020). De igual manera, modelos predictivos en educación a distancia evidencian que los factores asociados al acompañamiento institucional y la interacción con el entorno virtual presentan patrones diferenciados según sexo, aunque su efecto depende del contexto sociocultural (Seo et al., 2024). Este resultado no implica una brecha estructural en rendimiento, sino una posible variación en la experiencia subjetiva del soporte académico, lo que refuerza la necesidad de intervenciones focalizadas basadas en indicadores académicos y de percepción institucional más que en variables demográficas

En la Tabla 4 se presentan los resultados del análisis de varianza aplicado con el objetivo de determinar si existen diferencias estadísticamente significativas entre los grupos etarios evaluados. Este procedimiento permitió contrastar las medias obtenidas en cada dimensión

según rangos de edad, estimando la variabilidad intergrupala e intragrupal a través del estadístico F y su correspondiente nivel de significación, con el fin de precisar la influencia de la edad en los constructos analizados. Ver Tabla 4.

Los resultados presentados en la Tabla 4 evidencian que no existen diferencias estadísticamente significativas entre los grupos etarios en rendimiento académico, participación y compromiso, uso de tecnologías educativas, riesgo percibido de deserción y apoyo institucional, dado que los valores de p superan el umbral de 0,05. Este comportamiento sugiere estabilidad estructural de los constructos frente a la variable edad, lo que coincide con investigaciones que señalan que los factores asociados al abandono y al desempeño no dependen exclusivamente de variables demográficas, sino de condiciones institucionales y motivacionales más amplias (Dahal et al., 2019).

Tabla 4

Comparación de medias por grupos de edad en las dimensiones de los sistemas de análisis de aprendizaje mediante ANOVA de un factor

Asimismo, estudios sobre género y compromiso académico en contextos de vulnerabilidad muestran que las diferencias en involucramiento suelen estar más vinculadas a condiciones socioeconómicas que a características etarias específicas (Osiesi & Blignaut, 2024).

No obstante, se observa una diferencia significativa en la dimensión Factores Personales y Motivacionales ($F = 3,198$; $p = 0,044$), donde el grupo de 16–17 años presenta la media más alta. Este hallazgo puede interpretarse a la luz de enfoques que integran autodeterminación e interseccionalidad, los cuales sostienen que la percepción de competencia y autonomía varía según etapas del desarrollo y contextos socioculturales (Banda et al., 2025). Además, la literatura sobre participación femenina en contextos educativos evidencia que las transiciones evolutivas pueden fortalecer la autoeficacia y el compromiso cuando existen

Dimensiones	Edad	N	M	DT	F	p
Rendimiento Académico	14–15 años	27	15,30	3,05	1,045	0,355
	16–17 años	85	16,01	2,10		
	18 años o más	13	15,54	2,30		
	Total	125	15,81	2,35		
Participación y Compromiso Académico	14–15 años	27	16,22	3,23	0,279	0,757
	16–17 años	85	16,59	2,35		
	18 años o más	13	16,23	2,05		
	Total	125	16,47	2,52		
Uso de Tecnologías Educativas	14–15 años	27	15,96	3,71	0,100	0,905
	16–17 años	85	16,25	2,90		
	18 años o más	13	16,31	2,29		
	Total	125	16,19	3,02		
Factores Personales y Motivacionales	14–15 años	27	16,37	3,55	3,198	0,044
	16–17 años	85	17,71	1,96		
	18 años o más	13	17,00	2,55		
	Total	125	17,34	2,49		
Riesgo Percibido de Deserción Escolar	14–15 años	27	8,85	4,06	0,055	0,946
	16–17 años	85	8,74	3,27		
	18 años o más	13	9,08	3,88		
	Total	125	8,80	3,49		
Apoyo Institucional Percibido	14–15 años	27	13,89	3,56	2,752	0,068
	16–17 años	85	15,41	3,17		
	18 años o más	13	14,00	3,70		
	Total	125	14,94	3,35		

entornos pedagógicos inclusivos (Kasahun et al., 2025). Por lo tanto, la diferencia detectada no indica una brecha estructural por edad, sino una posible consolidación motivacional en etapas intermedias del ciclo formativo, lo que refuerza la necesidad de estrategias diferenciadas de acompañamiento académico.

En la Tabla 5 se presentan los estadísticos descriptivos y los contrastes inferenciales derivados del análisis de varianza aplicado para identificar posibles diferencias entre estudiantes de primero, segundo y tercer grado. Este procedimiento permitió comparar las medias de cada dimensión, estimando la variabilidad intergrupar mediante el estadístico F y su correspondiente nivel de significación, con el objetivo de determinar si el grado académico se asocia con variaciones relevantes en los sistemas de análisis de aprendizaje evaluados.

En la Tabla 5 se observan diferencias no significativas en rendimiento académico, participación, uso de tecnologías y riesgo percibido de deserción entre primero, segundo y tercer grado, lo que sugiere estabilidad estructural de estos indicadores a lo largo del trayecto formativo. No obstante, se identifican diferencias significativas en apoyo institucional percibido ($F = 5,781; p = 0,004$), con mayor media en segundo grado. Este patrón resulta coherente con modelos que vinculan la percepción de calidad y soporte institucional con variables de permanencia y satisfacción académica (Duque, 2014).

La evidencia empírica ha demostrado que el compromiso académico constituye un predictor relevante de la intención de abandono y que los factores contextuales, entre ellos el soporte institucional, modulan dicha relación (Truta et

Tabla 5

Diferencias en las dimensiones de los sistemas de análisis de aprendizaje según grado académico

Dimensiones	Grado	N	M	DT	F	p
Rendimiento Académico	Primero	38	15,21	2,90	2,017	0,138
	Segundo	30	16,30	2,20		
	Tercero	57	15,95	1,95		
	Total	125	15,81	2,35		
Participación y Compromiso Académico	Primero	38	16,50	3,13	0,699	0,499
	Segundo	30	16,90	2,26		
	Tercero	57	16,23	2,19		
	Total	125	16,47	2,52		
Uso de Tecnologías Educativas	Primero	38	16,08	3,93	0,129	0,879
	Segundo	30	16,43	2,14		
	Tercero	57	16,14	2,75		
	Total	125	16,19	3,02		
Factores Personales y Motivacionales	Primero	38	16,97	3,18	0,793	0,455
	Segundo	30	17,73	2,03		
	Tercero	57	17,39	2,17		
	Total	125	17,34	2,49		
Riesgo Percibido de Deserción Escolar	Primero	38	8,97	3,96	0,095	0,909
	Segundo	30	8,60	3,22		
	Tercero	57	8,79	3,34		
	Total	125	8,80	3,49		
Apoyo Institucional Percibido	Primero	38	13,87	3,94	5,781	0,004
	Segundo	30	16,53	2,40		
	Tercero	57	14,81	3,08		
	Total	125	14,9360	3,35469		

al., 2018). Asimismo, revisiones sistemáticas recientes en educación superior en línea subrayan que los servicios de apoyo y la calidad del entorno educativo inciden directamente en la continuidad académica (Rahmani et al., 2024), mientras que los contextos escolares con mayores niveles de apoyo atenúan el impacto del bajo desempeño sobre el compromiso cognitivo (Moreira et al., 2018). En este sentido, las diferencias detectadas por grado parecen responder menos a variaciones en desempeño y más a la percepción diferencial del entorno institucional, lo que refuerza la centralidad del apoyo organizacional como mecanismo preventivo frente a trayectorias de riesgo académico.

En la Tabla 6 se presentan los coeficientes de correlación bivariada que permiten examinar la dirección, magnitud y significación estadística de las asociaciones entre las variables del estudio. Este análisis facilita la identificación de patrones de relación entre el riesgo de deserción y los factores académicos, tecnológicos, motivacionales e institucionales, aportando evidencia empírica sobre la interdependencia estructural de los constructos evaluados.

Los resultados presentados en la Tabla 6 muestran relaciones estadísticamente significativas entre todas las variables analizadas ($p < .01$). El riesgo de deserción se

Tabla 6
Correlación de Learning Analytics Systems sobre la deserción escolar

Dimensiones	Test	Riesgo Percibido de Deserción Escolar	Rendimiento Académico	Participación y Compromiso Académico	Uso de Tecnologías Educativas	Factores Personales y Motivacionales	Apoyo Institucional Percibido
Riesgo Percibido de Deserción Escolar	Correlación de Pearson	1	-,292**	-,349**	-,241**	-,266**	-,268**
	Sig. (bilateral)		0,001	0,000	0,007	0,003	0,003
	N	125	125	125	125	125	125
Rendimiento Académico	Correlación de Pearson	-,292**	1	,657**	,454**	,539**	,409**
	Sig. (bilateral)	0,001		0,000	0,000	0,000	0,000
	N	125	125	125	125	125	125
Participación y Compromiso Académico	Correlación de Pearson	-,349**	,657**	1	,598**	,595**	,432**
	Sig. (bilateral)	0,000	0,000		0,000	0,000	0,000
	N	125	125	125	125	125	125
Uso de Tecnologías Educativas	Correlación de Pearson	-,241**	,454**	,598**	1	,555**	,323**
	Sig. (bilateral)	0,007	0,000	0,000		0,000	0,000
	N	125	125	125	125	125	125
Factores Personales y Motivacionales	Correlación de Pearson	-,266**	,539**	,595**	,555**	1	,393**
	Sig. (bilateral)	0,003	0,000	0,000	0,000		0,000
	N	125	125	125	125	125	125
Apoyo Institucional Percibido	Correlación de Pearson	-,268**	,409**	,432**	,323**	,393**	1
	Sig. (bilateral)	0,003	0,000	0,000	0,000	0,000	
	N	125	125	125	125	125	125

asocia de manera negativa con el rendimiento académico, la participación y compromiso académico, el uso de tecnologías educativas, los factores personales y motivacionales y el apoyo institucional percibido. Esto significa que, a mayor rendimiento, mayor participación o mayor apoyo, menor es el riesgo de abandono. Estos resultados coinciden con estudios que demuestran que las interacciones registradas en los entornos virtuales permiten identificar tempranamente a estudiantes en riesgo, incluso cuando solo se utilizan datos de actividad en plataformas educativas (Queiroga et al., 2020). Asimismo, revisiones sistemáticas en educación superior confirman que la combinación de datos académicos y conductuales fortalece los sistemas de alerta temprana para prevenir la deserción (de Oliveira et al., 2021).

Por otra parte, las correlaciones positivas y moderadas entre rendimiento, participación, uso tecnológico, factores motivacionales y apoyo institucional, con valores entre .323 y .657, indican que estas dimensiones funcionan de manera integrada. Cuando el estudiante participa activamente, utiliza los recursos digitales y percibe apoyo institucional, su desempeño tiende a mejorar y el riesgo de abandono disminuye. En contextos latinoamericanos, investigaciones realizadas en educación a distancia evidencian que variables como el acceso a la plataforma, la interacción en foros y la descarga de recursos son determinantes en la permanencia académica (García-Tinizaray et al., 2015). De igual manera, estudios recientes sobre ciencia de datos aplicada a la educación superior sostienen que los modelos predictivos permiten diseñar intervenciones personalizadas para fortalecer la retención estudiantil (Pinzón, 2024).

La Tabla 7 presenta los resultados del modelo de regresión lineal múltiple estimado para identificar los factores que predicen la deserción escolar. Se reportan los coeficientes no estandarizados (B), sus errores estándar, los coeficientes estandarizados (Beta), los valores t, los niveles de significancia estadística y los intervalos de confianza al 95%. Este análisis permite determinar la magnitud, dirección y relevancia estadística de cada predictor en la

explicación del riesgo de abandono, así como evaluar la consistencia de las hipótesis planteadas en el modelo teórico. Ver Tabla 7.

Los resultados expuestos en la Tabla 7 evidencian que todos los predictores incluidos en el modelo presentan coeficientes negativos y estadísticamente significativos sobre la deserción escolar, lo que indica que mayores niveles de rendimiento académico, participación y compromiso, uso de tecnologías educativas, factores personales y motivacionales, y apoyo institucional percibido se asocian con una menor probabilidad de abandono. Este patrón coincide con la evidencia de estudios longitudinales que identifican el bajo desempeño académico y la escasa integración escolar como factores críticos en la génesis del abandono, resaltando el carácter acumulativo y procesual de la deserción (Robison et al., 2017). Asimismo, investigaciones basadas en algoritmos de aprendizaje automático demuestran que variables académicas y conductuales tempranas permiten anticipar con alta precisión trayectorias de riesgo, lo que refuerza la validez explicativa de los predictores considerados (Jiménez-Gutiérrez et al., 2024; Sorensen, 2019).

En términos comparativos, la participación y compromiso académico y el rendimiento académico muestran los efectos estandarizados más intensos, lo que sugiere que la vinculación activa con el proceso formativo constituye un mecanismo central de retención. Este hallazgo resulta coherente con modelos teóricos que conciben el abandono como resultado de un debilitamiento progresivo del ajuste entre estudiante y entorno educativo, donde la intención de desertar emerge antes de la decisión final (Findeisen et al., 2024). A su vez, el efecto significativo del apoyo institucional percibido confirma que la percepción de acompañamiento y soporte actúa como factor protector, en línea con enfoques que enfatizan la necesidad de sistemas de alerta temprana sustentados en datos para orientar intervenciones focalizadas.

Conclusión

El presente estudio tuvo como propósito predecir la deserción escolar mediante Learning Analytics Systems basados en inteligencia artificial en el Bachillerato Técnico en Informática de la Unidad Educativa Patrimonio de la Humanidad. Los hallazgos evidencian el cumplimiento del objetivo general, al identificarse predictores estadísticamente significativos del riesgo de abandono y establecerse un modelo explicativo consistente. Asimismo, se responde afirmativamente a la pregunta de investigación, demostrando que es posible anticipar la deserción a partir de variables académicas, conductuales, motivacionales e institucionales procesadas mediante análisis estadístico inferencial.

Los resultados más relevantes indican que el rendimiento académico, la participación y compromiso, el uso de tecnologías educativas, los factores personales y motivacionales y el apoyo institucional percibido actúan como predictores significativos y de dirección negativa sobre el riesgo de deserción. La participación y compromiso académico presentó el mayor peso estandarizado, lo que confirma la centralidad del involucramiento activo en la permanencia escolar. Además, las correlaciones evidenciaron una estructura integrada entre desempeño, motivación, tecnología y soporte institucional, lo que refuerza la naturaleza multifactorial del abandono en contextos de educación técnica.

En cuanto a las limitaciones, el diseño transversal impide establecer relaciones causales definitivas y restringe el análisis de trayectorias longitudinales del abandono. La investigación se desarrolló en una sola institución educativa, lo que puede limitar la generalización de los resultados a otros contextos con características sociodemográficas distintas. Adicionalmente, aunque el modelo mostró consistencia estadística, no se incorporaron algoritmos avanzados de aprendizaje automático comparativos que permitan contrastar niveles de precisión predictiva entre distintos enfoques.

Como líneas futuras de investigación, se recomienda implementar diseños longitudinales que permitan analizar la evolución del riesgo de deserción a lo largo del ciclo formativo, así como integrar técnicas de machine learning supervisado y modelos híbridos con validación cruzada. También resulta pertinente ampliar la muestra a múltiples instituciones técnicas para evaluar la robustez externa del modelo y desarrollar sistemas de alerta temprana institucionales que articulen analítica predictiva con estrategias de intervención pedagógica personalizadas. De este modo, se fortalecerá la toma de decisiones basada en datos y la prevención temprana del abandono escolar en educación media técnica.

Tabla 7

Predictores de la deserción escolar

Predictores	Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.	95,0% intervalo de confianza para B		Umbral Hipótesis
	B	Desv. Error	Beta			Límite inferior	Límite superior	
Rendimiento Académico	-0,433	0,128	-0,292	-3,385	0,001	-0,686	-0,180	Aceptada
Participación y Compromiso Académico	-0,483	0,117	-0,349	-4,130	0,000	-0,715	-0,252	Aceptada
Uso de Tecnologías Educativas	-0,278	0,101	-0,241	-2,751	0,007	-0,478	-0,078	Aceptada
Factores Personales y Motivacionales	-0,373	0,122	-0,266	-3,061	0,003	-0,614	-0,132	Aceptada
Apoyo Institucional Percibido	-0,278	0,090	-0,268	-3,084	0,003	-0,457	-0,100	Aceptada

Referencias bibliográficas

- Ademola, R. (2023). The Impact of Virtual Learning Environments on Student Achievement. *Journal of Education Review Provision*, 1(3), 53–58. <https://doi.org/10.55885/jerp.v1i3.195>
- Alamo, E. M.-C. (2024). Análisis de estrategias innovadoras para retención estudiantil con inteligencia artificial: una perspectiva multidisciplinaria. *European Public & Social Innovation Review*, 9, 1–20. <https://doi.org/10.31637/epsir-2024-440>
- Aparicio Colino, A., Arroyo-Barrigüete, J. L., Hernández, A., & Sánchez-Ávila, C. (2025). Gender and Academic Indicators in First-Year Engineering Dropout: A Multi-Model Approach. *IEEE Access*, 13, 155532–155546. <https://doi.org/10.1109/ACCESS.2025.3605776>
- Banda, L. O. L., Banda, J. T., Mpasó, C. N., Xuefu, X., Mwaene, E., & Banda, C. V. (2025). Girls' Education Still at Risk? Interplay of SDT and Intersectionality in Dropout Analysis. *Gender and Sustainability in the Global South*, 2(1), 139–163. <https://doi.org/10.1515/gsgs-2024-0005>
- Barragán Moreno, S. P., & Guzmán Rincón, A. (2025). Digital divide as an explanatory variable for dropout in higher education. *International Journal of Educational Technology in Higher Education*, 22(1), 60. <https://doi.org/10.1186/s41239-025-00550-0>
- Bressane, A., Spalding, M., Zwirn, D., Loureiro, A. I. S., Bankole, A. O., Negri, R. G., de Brito Junior, I., Formiga, J. K. S., Medeiros, L. C. de C., Pampuch Bortolozo, L. A., & Moruzzi, R. (2022). Fuzzy Artificial Intelligence—Based Model Proposal to Forecast Student Performance and Retention Risk in Engineering Education: An Alternative for Handling with Small Data. *Sustainability*, 14(21), 14071. <https://doi.org/10.3390/su142114071>
- Caicedo Ibáñez, H. R., Sánchez Ludeña, L. E., Rivera Ibáñez, V. A., Vivanco Molina, M. S., & Becerra Vélez, C. E. (2025). Transformación Digital y Acceso a la Educación Superior: El Rol de la Inteligencia Artificial en la Formación de estudiantes de Bachillerato. *Revista Veritas de Difusão Científica*, 6(1), 1309–1331. <https://doi.org/10.61616/rvdc.v6i1.461>
- Chari, S. G. (2024). Bridging Gaps, Building Futures: Tackling Socio-Economic Disparities through Education and Technology. *London Journal of Research In Humanities and Social Sciences*, 24(16), 17–87. <https://journalspress.uk/index.php/LJRHSS/article/view/1122>
- Choez Calderón, C. J., & Miranda Bajaña, R. S. (2024). El rol de la inteligencia artificial en la educación inclusiva: Oportunidades y retos para la enseñanza personalizada. *Revista Científica Multidisciplinar G-Nerando*, 5(2). <https://doi.org/10.60100/rcmg.v5i2.303>
- Córdova-Esparza, D.-M., Terven, J., Romero-González, J.-A., Córdova-Esparza, K.-E., López-Martínez, R.-E., García-Ramírez, T., & Chaparro-Sánchez, R. (2025). Predicting and Preventing School Dropout with Business Intelligence: Insights from a Systematic Review. *Information*, 16(4), 326. <https://doi.org/10.3390/info16040326>
- Dahal, T., Topping, K., & Levy, S. (2019). Educational factors influencing female students' dropout from high schools in Nepal. *International Journal of Educational Research*, 98, 67–76. <https://doi.org/10.1016/j.ijer.2019.08.010>
- 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 2021, Vol. 5, Page 64*, 5(4), 64. <https://doi.org/10.3390/bdcc5040064>

- Del Carpio-Mendoza, R. (2024). Predicción del rendimiento académico utilizando modelos de aprendizaje automático: Una revisión sistemática de la literatura. *593 Digital Publisher CEIT*, 9(6), 1038–1054. <https://doi.org/10.33386/593dp.2024.6.2797>
- Duque, L. C. (2014). A framework for analysing higher education performance: students' satisfaction, perceived learning outcomes, and dropout intentions. *Total Quality Management & Business Excellence*, 25(1–2), 1–21. <https://doi.org/10.1080/14783363.2013.807677>
- Félix Tipian, L. E. (2025). Monitoreo y acompañamiento académico de estudiantes de educación superior utilizando tecnologías emergentes. *E-Revista Multidisciplinaria Del Saber*, 1–9. <https://doi.org/10.61286/e-rms.v3i.194>
- Fierro Saltos, W. R., Fierro Saltos, F. E., Elizabeth Alexandra, V. S., & Rivera Guzmán, E. F. (2025). Leveraging Artificial Intelligence for Sustainable Tutoring and Dropout Prevention in Higher Education: A Scoping Review on Digital Transformation. *Information*, 16(9), 819. <https://doi.org/10.3390/info16090819>
- Findeisen, S., Brodsky, A., Michaelis, C., Schimmelpenningh, B., & Seifried, J. (2024). Dropout intention: a valid predictor of actual dropout? *Empirical Research in Vocational Education and Training*, 16(1), 10. <https://doi.org/10.1186/s40461-024-00165-1>
- García-Tinizaray, D., Ordoñez-Briceño, K., Carlos, J., & Loja, T.-D. (2015). Learning analytics para predecir la deserción de estudiantes a distancia. *Campus Virtuales*, 3(1), 120–126. <https://uajournals.com/ojs/index.php/campusvirtuales/article/view/55>
- Granata, M. (2022). The OECD and technical education in post-war Mediterranean Europe. *Labor History*, 63(1), 101–119. <https://doi.org/10.1080/0023656X.2022.2057459>
- Jayaram, Y., & Sundar, D. (2022). Enhanced Predictive Decision Models for Academia and Operations through Advanced Analytical Methodologies. *International Journal of Artificial Intelligence, Data Science, and Machine Learning*, 3, 113–122. <https://doi.org/10.63282/3050-9262.IJAIDSML-V3I4P113>
- Jiménez-Gutiérrez, A. L., Mota-Hernández, C. I., Mezura-Montes, E., & Alvarado-Corona, R. (2024). Application of the performance of machine learning techniques as support in the prediction of school dropout. *Scientific Reports* 2024 14:1, 14(1), 3957-. <https://doi.org/10.1038/s41598-024-53576-1>
- Kasahun, M., Hailemariam, G., Tadele, T., Duba, O., Lemma, T., & Kore, B. (2025). Enhancing Female Students' Classroom Participation in Economics to Improve Academic Performance: A Case Study of 12th-Grade Social Science Students at Shaleka-Jateni Secondary School. *International Journal of Advance Research in Education & Literature (ISSN 2208-2441)*, 11(2), 41–73. <https://doi.org/10.61841/2rren667>
- López-Meneses, E., López-Catalán, L., Pelicano-Piris, N., & Mellado-Moreno, P. C. (2025). Artificial Intelligence in Educational Data Mining and Human-in-the-Loop Machine Learning and Machine Teaching: Analysis of Scientific Knowledge. *Applied Sciences*, 15(2), 772. <https://doi.org/10.3390/app15020772>
- Moreira, P. A. S., Dias, A., Matias, C., Castro, J., Gaspar, T., & Oliveira, J. (2018). School effects on students' engagement with school: Academic performance moderates the effect of school support for learning on students' engagement. *Learning and Individual Differences*, 67, 67–77. <https://doi.org/10.1016/j.lindif.2018.07.007>
- Moreira-Choez, J. S., Núñez-Naranjo, A. F., Carrasco-Valenzuela, A. C., López-López, H. L., Vázquez Meza, J. A., &

- Sabando-García, A. R. (2025). Machine Learning Algorithms to Predict Digital Competencies in University Faculty. *F1000Research*, *14*, 573. <https://doi.org/10.12688/f1000research.165342.1>
- Osiesi, M. P., & Blignaut, S. (2024). Role of gender and perceived poverty on learners' educational life and academic engagement in Ekiti State primary schools, Nigeria. *Education 3-13*, *1*–15. <https://doi.org/10.1080/03004279.2024.2418324>
- Paredes Gallardo, C. (2024). Aplicación de la inteligencia artificial en el ámbito educativo. Análisis de buenas prácticas y recomendaciones. *Revista de Educación y Derecho*, (2-Extraordinario), 512–539. <https://doi.org/10.1344/REYD2024.2-Extraordinario.49204>
- Pinzón, L. (2024). Personalización del Aprendizaje mediante Ciencia de Datos: Estrategias y Aplicaciones en la Educación Superior. *Revista Latinoamericana de Calidad Educativa*, *2*(1), 55–60. <https://doi.org/10.70625/rlice/71>
- Queiroga, E. M., Lopes, J. L., Kappel, K., Aguiar, M., Araújo, R. M., Munoz, R., Villarroel, R., & Cechinel, C. (2020). A Learning Analytics Approach to Identify Students at Risk of Dropout: A Case Study with a Technical Distance Education Course. *Applied Sciences*, *10*(11), 3998. <https://doi.org/10.3390/app10113998>
- Rahmani, A. M., Groot, W., & Rahmani, H. (2024). Dropout in online higher education: a systematic literature review. *International Journal of Educational Technology in Higher Education*, *21*(1), 19. <https://doi.org/10.1186/s41239-024-00450-9>
- Robison, S., Jagers, J., Rhodes, J., Blackmon, B. J., & Church, W. (2017). Correlates of educational success: Predictors of school dropout and graduation for urban students in the Deep South. *Children and Youth Services Review*, *73*, 37–46. <https://doi.org/10.1016/j.childyouth.2016.11.031>
- Ryan, E., & Poole, C. (2019). Impact of Virtual Learning Environment on Students' Satisfaction, Engagement, Recall, and Retention. *Journal of Medical Imaging and Radiation Sciences*, *50*(3), 408–415. <https://doi.org/10.1016/j.jmir.2019.04.005>
- Seo, E.-Y., Yang, J., Lee, J.-E., & So, G. (2024). Predictive modelling of student dropout risk: Practical insights from a South Korean distance university. *Heliyon*, *10*(11), e30960. <https://doi.org/10.1016/j.heliyon.2024.e30960>
- Silva, F. da C., Santana, A. M., & Feitosa, R. M. (2025). An Investigation Into Dropout Indicators in Secondary Technical Education Using Explainable Artificial Intelligence. *IEEE Revista Iberoamericana de Tecnologías Del Aprendizaje*, *20*, 105–114. <https://doi.org/10.1109/RITA.2025.3566095>
- Sorensen, L. C. (2019). “Big Data” in Educational Administration: An Application for Predicting School Dropout Risk. *Educational Administration Quarterly*, *55*(3), 404–446. <https://doi.org/10.1177/0013161X18799439>
- Suberviola Ovejas, I. (2024). The Influence of Gender on Early School Dropout. *The International Journal of Interdisciplinary Educational Studies*, *20*(1), 119–141. <https://doi.org/10.18848/2327-011X/CGP/v20i01/119-141>
- Torres Zapata, Á. E., Sánchez Domínguez, J. P., Brito Cruz, T. del J., & Moguel Ceballos, J. E. (2026). Niveles de estrés y su relación con el rendimiento académico y la reprobación en universitarios. *CPU-e, Revista de Investigación Educativa*, (42). <https://doi.org/10.25009/cpue.v1i42.2928>
- Truta, C., Parv, L., & Topala, I. (2018). Academic Engagement and Intention to Drop Out: Levers for Sustainability in Higher Education. *Sustainability*,

- 10(12), 4637. <https://doi.org/10.3390/su10124637>
- Villegas-Ch, W., García-Ortiz, J., & Sánchez-Viteri, S. (2024). Application of Artificial Intelligence in Online Education: Influence of Student Participation on Academic Retention in Virtual Courses. *IEEE Access*, 12, 73045–73065. <https://doi.org/10.1109/ACCESS.2024.3403758>
- WenYang Cao, & Nhu Tam Mai. (2025). Predictive analytics for student success: AI-driven early warning systems and intervention strategies for educational risk management. *Educational Research and Human Development*, 2(2). <https://doi.org/10.61784/erhd3042>
- Wongwatkit, C., Panjaburee, P., Srisawasdi, N., & Seprum, P. (2020). Moderating effects of gender differences on the relationships between perceived learning support, intention to use, and learning performance in a personalized e-learning. *Journal of Computers in Education*, 7(2), 229–255. <https://doi.org/10.1007/s40692-020-00154-9>
- Zambrana Copaja, R., Salinas Montemayor, A. D., Macías García, F. A., Ernesto Escobar, E., Zambrana Copaja, R., Salinas Montemayor, A. D., Macías García, F. A., & Ernesto Escobar, E. (2026). Inteligencia artificial en la educación superior para promover un aprendizaje personalizado e inclusivo: una revisión sistemática. *Revista InveCom*, 6(2). <https://doi.org/10.5281/ZENODO.16147008>

Quito, 10 de marzo del 2026

Estimados

Silvia Verónica Caiza Criollo

Martha Cecilia Aguirre Revelo

Roxana Mariella Ronquillo Murrieta

Jennifer Sobeida Moreira Choez

V11-N2-3932

Presente

Reciban un cordial saludo del equipo de la revista 593 Digital Publisher CEIT, ISSN# 2588-0705, esta revista es indexada en Latindex con catálogo v2.0, su proceso contempla un arbitraje de pares ciegos y es multidisciplinar, evalúa la pertinencia en la calidad de investigación y sus dinámicas propias relacionadas al tema de estudio, con el fin de garantizar estándares de exigencia académica.

Este documento certifica que ha concluido la fase de revisión de pares, por lo tanto, el artículo es aceptado para la publicación en el V11-N2, edición continua, por los autores **Silvia Caiza, Martha Aguirre, Roxana Ronquillo, Jennifer Moreira**, con el tema **"Learning Analytics Systems basado en inteligencia artificial como predictores de deserción en Bachillerato Técnico en Informática"**, cuyos resultados obedecen a un proceso de investigación previo del/os autor/es.

doi.org/10.33386/593dp.2026.2.3932

Agradecemos su publicación y le deseamos éxitos en su carrera como investigadores.

Renato Revelo Dr.(c)

Editor General



UNEMI

UNIVERSIDAD ESTATAL DE MILAGRO

¡Evolución académica!

@UNEMIEcuador

