

Analítica del aprendizaje explicable para predecir el abandono universitario en entornos híbridos

Explainable learning analytics to predict college dropout rates in hybrid settings



Herrera-Castrillo, Clifford Jerry ¹



<https://orcid.org/0000-0002-7663-2499>



cliffor.herrera@unan.edu.ni



Nicaragua, Estelí, Universidad Nacional Autónoma de Nicaragua.

Autor de correspondencia ¹



DOI / URL: <https://doi.org/10.55813/gaea/revistacec/v3/n3/54>

Resumen: El abandono universitario en entornos híbridos constituye un problema multidimensional cuya predicción exige integrar las trayectorias académicas con las condiciones socioeconómicas, psicológicas, institucionales y digitales del estudiantado. El objetivo fue analizar y sistematizar la evidencia necesaria para orientar el desarrollo y la evaluación de una analítica del aprendizaje explicable aplicada a universidades latinoamericanas. Se realizó una investigación cualitativa, documental y transversal, mediante búsqueda estructurada en cinco bases académicas, selección de publicaciones recientes y análisis deductivo de contenido sobre factores de riesgo, algoritmos, explicabilidad, calibración y equidad. Los resultados mostraron que el abandono se relacionó con la acumulación de riesgos y no con indicadores aislados de participación digital; asimismo, los modelos de ensamble alcanzaron exactitudes agregadas cercanas al 86–88 %, aunque solo alrededor del 24 % de los estudios incorporó técnicas explicativas. La evidencia también reveló una limitada validación temporal, institucional e interseccional, pues predominó el uso de datos procedentes de una sola institución. Estos hallazgos indican que la precisión predictiva no garantiza interpretaciones pedagógicamente pertinentes ni decisiones equitativas. Se concluyó que la utilidad de estos sistemas depende de articular desempeño, explicabilidad, calibración, transferencia, supervisión humana y responsabilidad institucional.

Palabras clave: abandono universitario; analítica del aprendizaje; inteligencia artificial explicable; educación híbrida; predicción académica.



Check for updates

Recibido: 30/May/2026

Aceptado: 28/Jun/2026

Publicado: 27/Jul/2026

Cita: Herrera-Castrillo, C. J. (2026). Analítica del aprendizaje explicable para predecir el abandono universitario en entornos híbridos. *Revista Científica Enfoques Del Conocimiento*, 3(3), 44-64. <https://doi.org/10.55813/gaea/revistacec/v3/n3/54>

Revista Científica Enfoques del Conocimiento (RCEC)

<https://www.blez.edu.ec>

<https://revistacec.blez.edu.ec>

revistacec@blez.edu.ec

© 2026. Este artículo es un documento de acceso abierto distribuido bajo los términos y condiciones de la **Licencia Creative Commons, Atribución-NoComercial 4.0 Internacional**.



Abstract:

University dropout in hybrid environments is a multidimensional problem whose prediction requires integrating academic trajectories with students' socioeconomic, psychological, institutional, and digital conditions. The objective was to analyze and systematize the evidence needed to guide the development and evaluation of explainable learning analytics applied to Latin American universities. A qualitative, documentary, and cross-sectional study was conducted through a structured search in five academic databases, the selection of recent publications, and deductive content analysis focused on risk factors, algorithms, explainability, calibration, and equity. The results showed that dropout was associated with the accumulation of risks rather than with isolated indicators of digital participation; likewise, ensemble models achieved aggregated accuracy levels of approximately 86–88%, although only about 24% of the studies incorporated explainability techniques. The evidence also revealed limited temporal, institutional, and intersectional validation, as data from a single institution predominated. These findings indicate that predictive accuracy does not guarantee pedagogically relevant interpretations or equitable decisions. It was concluded that the usefulness of these systems depends on integrating performance, explainability, calibration, transferability, human oversight, and institutional responsibility.

Keywords: university dropout; learning analytics; explainable artificial intelligence; hybrid education; academic prediction.

1. Introducción

La expansión de la educación superior latinoamericana ha ampliado las oportunidades de movilidad social, pero no ha garantizado trayectorias universitarias continuas ni titulaciones oportunas. La región reúne aproximadamente 30 millones de estudiantes distribuidos en unas 10.000 instituciones y 60.000 programas, lo que configura un sistema amplio, heterogéneo y crecientemente digitalizado. Sin embargo, una estimación regional para personas de 25 a 29 años que habían ingresado a la educación superior mostró que solo el 46 % había culminado sus estudios, mientras el 22 % los había abandonado y el 32 % continuaba matriculado sin finalizar. Estas cifras permiten delimitar el abandono universitario como una interrupción de la trayectoria formativa antes de obtener la titulación, diferenciándolo del rezago o la permanencia prolongada. En los entornos híbridos, esta trayectoria comprende tanto la participación presencial como las interacciones registradas en plataformas digitales, evaluaciones y servicios institucionales. Por ello, anticipar el riesgo exige analizar el proceso acumulativo que precede a la desvinculación y no únicamente el estado administrativo final del estudiante (Ferreira et al., 2017; Inter-American Development Bank [IDB], 2021).

La magnitud del problema se explica por la interacción de factores académicos, económicos, personales, institucionales y macrosociales, cuyos efectos varían según la carrera, el momento de la trayectoria y las condiciones del entorno educativo. Una revisión regional identificó 67 variables organizadas en cuatro niveles ecológicos —estudiante, institución, sistema educativo y contexto macrosocial—, lo que evidencia que el abandono no puede atribuirse exclusivamente al rendimiento individual. Entre los factores asociados destacan la reprobación, la baja participación académica, las dificultades financieras, el empleo simultáneo, la débil integración social, la insatisfacción con la enseñanza y las limitaciones de conectividad. Sus consecuencias incluyen pérdida de tiempo y recursos familiares, deterioro de la confianza académica, menor disponibilidad futura de capital humano y gastos institucionales que no se traducen en graduación. El impacto económico resulta especialmente relevante porque, en promedio regional, una persona con educación superior completa puede percibir más del doble de los ingresos de quien solo concluyó la educación secundaria. La inacción, por tanto, profundiza desigualdades preexistentes y reduce la eficiencia social de la inversión pública y privada destinada a la formación universitaria (Chiarino et al., 2024; Ferreyra et al., 2017).

La transformación digital posterior a la emergencia sanitaria consolidó modalidades que combinan actividades presenciales, trabajo asincrónico y encuentros virtuales, incrementando tanto la flexibilidad educativa como la complejidad de las trayectorias observables. En una consulta realizada a 73 instituciones de 14 países latinoamericanos y caribeños, tres cuartas partes de sus responsables calificaron la transformación digital como muy importante, aunque solo una cuarta parte consideró que su institución poseía una madurez digital igualmente elevada. Esta brecha implica que los sistemas híbridos generan grandes volúmenes de datos —sesiones, accesos, entregas, calificaciones, participación y regularidad— sin que necesariamente existan capacidades suficientes para convertirlos en decisiones pedagógicas. Un estudio desarrollado con 133 estudiantes de un curso combinado mostró que el compromiso y la constancia en el uso de recursos digitales permitían detectar tempranamente desempeños insuficientes. No obstante, una baja actividad en línea puede reflejar desmotivación, dificultades tecnológicas, estrategias de estudio fuera de la plataforma o restricciones laborales, por lo que su interpretación aislada puede producir clasificaciones erróneas. La analítica del aprendizaje debe, en consecuencia, relacionar las huellas digitales con información académica, socioeconómica e institucional antes de atribuirles significado predictivo (IDB, 2021; Saqr et al., 2017).

Pese al crecimiento de la investigación, la literatura regional continúa mostrando una orientación predominantemente descriptiva y fragmentada. Una revisión de 217 estudios latinoamericanos y caribeños encontró que el 76 % empleó metodologías cuantitativas, frente al 10 % de investigaciones cualitativas y el 14 % de estudios mixtos, mientras apenas el 25 % alcanzó una finalidad explicativa. Asimismo, el 76 % de los trabajos se concentró en el abandono y solo el 24 % examinó la permanencia, lo que limita la comprensión de los mecanismos protectores que podrían incorporarse

a las intervenciones. En el ámbito de la predicción automatizada, una revisión de 75 estudios publicados entre 2019 y 2024 registró precisiones cercanas al 86–88 % para modelos de ensamble, aunque constató dependencia de bases pertenecientes a una sola institución, escaso tratamiento de la evolución temporal y limitada evaluación de la equidad. También permanecen subrepresentadas variables como autoeficacia, pertenencia, motivación, resiliencia y restricciones socioeconómicas, pese a su relevancia teórica para explicar la continuidad universitaria. El vacío resulta particularmente crítico en los entornos híbridos latinoamericanos, donde todavía falta determinar si los modelos conservan su desempeño entre carreras, periodos, modalidades y grupos sociales diferentes (Alyahyan & Düştegör, 2020; Chiarino et al., 2024; Lopez-Muñoz et al., 2026).

El vacío se profundiza porque una predicción estadísticamente precisa no constituye, por sí sola, una explicación pedagógicamente útil. La inteligencia artificial explicable permite identificar las variables que incrementan o reducen el riesgo, ofreciendo interpretaciones en dos escalas complementarias: una global, referida al comportamiento general del modelo, y otra local, centrada en cada estudiante. Esta capacidad puede favorecer que docentes, tutores y gestores comprendan por qué una trayectoria fue clasificada como vulnerable y distingan factores potencialmente modificables de condiciones estructurales que requieren apoyos institucionales. No obstante, investigaciones recientes advierten que la transparencia algorítmica no elimina los errores, pues un estudio con 126 estudiantes y cinco algoritmos encontró que algunas explicaciones se apoyaban en predictores pedagógicamente poco plausibles. De manera similar, los modelos interpretables de abandono han mostrado utilidad para orientar intervenciones personalizadas, pero su transferencia depende de la calidad, representatividad y contexto de los datos utilizados. La cuestión pendiente no consiste únicamente en explicar la predicción, sino en establecer si esa explicación es estable, justa y suficientemente pertinente para respaldar decisiones humanas (Khosravi et al., 2022; Nagy & Molontay, 2024; Saqr & López-Pernas, 2024).

La convergencia de registros académicos y trazas de plataformas hace viable estudiar el fenómeno mediante datos que suelen producirse durante el funcionamiento ordinario de los entornos híbridos, siempre que exista acceso institucional legítimo y una delimitación temporal coherente. La experiencia acumulada demuestra que incluso bases de escala moderada, como la integrada por 133 participantes en un curso combinado, permiten construir alertas tempranas cuando se analizan variables de actividad antes de finalizar el periodo académico. Esta disponibilidad reduce costos de recolección primaria y posibilita evaluar diferentes modelos mediante recursos computacionales accesibles, sin reemplazar la interpretación educativa ni el acompañamiento profesional. Su utilización requiere, al menos, cuatro salvaguardas: minimización de datos, desidentificación, control de acceso y supervisión humana sobre cualquier intervención derivada del riesgo estimado. También debe evitarse que las predicciones se conviertan en etiquetas permanentes o sanciones, dado que el propósito legítimo de la analítica es ampliar apoyos y no restringir oportunidades. En

términos sociales, teóricos y metodológicos, el estudio resulta conveniente porque conecta la explicación multicausal del abandono con herramientas reproducibles de decisión, manteniendo la privacidad, la transparencia y la responsabilidad institucional como condiciones de aplicación (Pardo & Siemens, 2014; Saqr et al., 2017).

Sobre esa base empírica, el objetivo general del estudio será desarrollar y evaluar un modelo de analítica del aprendizaje explicable para predecir el abandono de estudiantes universitarios en entornos híbridos latinoamericanos. Este propósito se concretará mediante cuatro objetivos específicos articulados con las brechas identificadas. El primero buscará analizar la relación entre variables socioeconómicas, académicas, institucionales y de interacción digital con la ocurrencia del abandono; el segundo determinará el desempeño predictivo de modelos estadísticos y de aprendizaje automático. El tercero comparará las explicaciones globales y locales para identificar los factores que contribuyen al riesgo en la población y en cada trayectoria individual. El cuarto estimará la calibración y la equidad del modelo entre grupos sociodemográficos, programas y patrones de participación híbrida, relacionando sus resultados con criterios institucionales de intervención temprana. Para asegurar una evaluación verificable, el desempeño deberá examinarse mediante indicadores complementarios —como área bajo la curva, precisión, sensibilidad, puntuación F1 y calibración— y no mediante un único porcentaje de aciertos (Alyahyan & Düşteğör, 2020; Khosravi et al., 2022).

La contribución original radicará en integrar los cuatro niveles ecológicos del abandono con las dos escalas de explicabilidad y con datos procedentes de la interacción presencial y digital. Esta articulación permitirá superar enfoques que reducen el fenómeno a calificaciones históricas o que privilegian la precisión algorítmica sin examinar la utilidad educativa de sus resultados. El trabajo distinguirá tres componentes frecuentemente confundidos —predicción, explicación e intervención—, de modo que una probabilidad elevada no se interprete automáticamente como una decisión definitiva. En el plano teórico, aportará evidencia sobre la interacción entre condiciones estructurales, integración universitaria y comportamiento digital; en el metodológico, ofrecerá un procedimiento evaluable para contrastar rendimiento, calibración, interpretabilidad y equidad. En el ámbito práctico, favorecerá alertas acompañadas de razones comprensibles, susceptibles de revisión por equipos académicos antes de asignar tutorías, orientación o apoyos financieros. De esta manera, la investigación responderá a la escasez de modelos regionales, explicables y contextualizados, transformando las huellas de los entornos híbridos en información preventiva sin desatender la autonomía ni la diversidad del estudiantado (Chiarino et al., 2024; Khosravi et al., 2022; Saqr & López-Pernas, 2024).

2. Materiales y métodos

La investigación se desarrolló desde una orientación cualitativa, puesto que se buscó interpretar cómo la literatura científica conceptualizó, diseñó y justificó el uso de la

analítica del aprendizaje explicable para anticipar el abandono universitario en entornos híbridos. Esta elección permitió examinar los significados atribuidos a la explicabilidad, la transparencia algorítmica, los factores de riesgo y la intervención temprana, en lugar de limitar el análisis a frecuencias o métricas de clasificación. La predicción se abordó, por tanto, como un objeto conceptual y metodológico documentado en investigaciones previas, y no como el entrenamiento de un algoritmo con registros individuales. También se consideró que las explicaciones educativas dependían de las necesidades de estudiantes, docentes, tutores y responsables institucionales, por lo que requerían una lectura contextualizada de los modelos. Esta orientación resultó coherente con un campo en el que la utilidad de una explicación no se redujo a su exactitud técnica, sino que incluyó su comprensibilidad, pertinencia y capacidad para apoyar decisiones humanas (Flick, 2022; Khosravi et al., 2022).

Esa orientación interpretativa condujo a organizar el estudio mediante un diseño transversal, dado que el corpus documental se examinó en un único corte analítico y no se siguió longitudinalmente la evolución de instituciones, estudiantes o sistemas predictivos. El corte quedó delimitado por documentos publicados entre enero de 2021 y diciembre de 2025, periodo que permitió incorporar investigaciones recientes sobre educación híbrida, abandono universitario y explicabilidad algorítmica. Aunque algunos estudios revisados pudieron haber utilizado datos longitudinales, cada publicación se trató como una unidad documental disponible dentro de la ventana establecida. En consecuencia, el diseño no pretendió demostrar cambios temporales ni establecer relaciones causales entre los factores identificados y la desvinculación estudiantil. Su finalidad consistió en reconstruir el estado reciente del conocimiento y reconocer regularidades, divergencias y vacíos metodológicos presentes en la producción científica (Flick, 2022; Morgan, 2022).

La coherencia del diseño se reforzó mediante una investigación documental sustentada en artículos científicos, revisiones, capítulos académicos y documentos técnicos que desarrollaron aplicaciones de analítica del aprendizaje, inteligencia artificial explicable o predicción del abandono en educación superior. La unidad de análisis estuvo constituida por cada documento que aportó información verificable sobre fuentes de datos, definición del abandono, variables predictoras, técnicas analíticas, formas de explicación, actores destinatarios o consideraciones éticas. La delimitación geográfica priorizó investigaciones realizadas en América Latina o referidas explícitamente a sus sistemas universitarios, aunque se admitieron estudios internacionales cuando presentaron marcos metodológicos transferibles a entornos híbridos regionales. No se definió una población de estudiantes ni se calculó una muestra probabilística, porque el estudio no recolectó información primaria ni buscó estimar proporciones poblacionales. Esta decisión respondió a la naturaleza documental del trabajo y a la necesidad de analizar críticamente una literatura regional en la que los factores académicos, individuales, económicos e institucionales se habían tratado de manera heterogénea (Heredia & Carcausto-Calla, 2024; Morgan, 2022).

La búsqueda documental se efectuó de manera estructurada en Scopus, Web of Science, ERIC, SciELO y Redalyc, con el propósito de combinar cobertura internacional y visibilidad de la producción latinoamericana. Se utilizaron expresiones en español, inglés y portugués relacionadas con “abandono universitario”, “deserción estudiantil”, “student dropout”, “evasão universitária”, “analítica del aprendizaje”, “learning analytics”, “aprendizaje híbrido”, “blended learning”, “inteligencia artificial explicable” y “explainable artificial intelligence”. Los términos se combinaron mediante los operadores booleanos AND y OR, y se adaptaron a los campos de título, resumen y palabras clave disponibles en cada base. También se revisaron las referencias de los documentos elegibles para identificar trabajos que no hubieran sido recuperados mediante la búsqueda inicial. El procedimiento se documentó mediante una estrategia reproducible que registró la base consultada, la fecha de búsqueda, la ecuación empleada y las decisiones de selección, conforme a las recomendaciones contemporáneas para síntesis de evidencia (JBI, 2024).

La selección incluyó publicaciones comprendidas en el periodo establecido, disponibles en español, inglés o portugués y centradas en estudiantes universitarios, educación superior híbrida o modelos aplicables a la predicción explicable del abandono. Se admitieron estudios empíricos, revisiones y propuestas metodológicas que describieron con suficiente claridad sus datos, variables, algoritmos, técnicas de explicación o implicaciones educativas. Se excluyeron textos duplicados, resúmenes sin documento completo, publicaciones comerciales, estudios exclusivamente escolares, trabajos sobre abandono de plataformas no universitarias y artículos que mencionaron la inteligencia artificial sin relacionarla con permanencia o riesgo académico. La evaluación se realizó primero mediante títulos y resúmenes y, posteriormente, mediante lectura completa de los documentos potencialmente pertinentes. Debido a que no se proporcionó una base definitiva de resultados ni un registro de cribado ejecutado, no se incorporaron cantidades de documentos identificados, excluidos o incluidos, pues dichos valores debían consignarse únicamente después de cerrar y auditar la búsqueda (JBI, 2024; Morgan, 2022).

Los documentos seleccionados se organizaron en una matriz de extracción que recogió autoría, año, país, modalidad educativa, población estudiada, fuente de datos, definición operativa del abandono, variables analizadas, método predictivo, procedimiento de validación y tipo de explicación producido. La matriz también registró los destinatarios de las explicaciones, el momento de generación de la alerta, las acciones institucionales sugeridas y los riesgos asociados con sesgos, privacidad o etiquetamiento del estudiante. El abordaje deductivo partió de categorías derivadas de la literatura sobre abandono universitario y del marco XAI-ED, entre ellas factores académicos, individuales, económicos e institucionales; actores involucrados; beneficios esperados; modelos empleados; presentación de explicaciones y posibles efectos adversos. Estas categorías funcionaron como referentes analíticos previos y no como variables destinadas a pruebas estadísticas. La estructura permitió relacionar la dimensión sociopedagógica del abandono con los componentes técnicos y

humanos de la explicabilidad educativa (Heredia & Carcausto-Calla, 2024; Khosravi et al., 2022).

El análisis se desarrolló mediante una codificación cualitativa de contenido, orientada a identificar patrones recurrentes, contrastes conceptuales y ausencias relevantes en el corpus. En una primera lectura se verificó la pertinencia de cada documento y se reconocieron las unidades textuales vinculadas con las categorías deductivas; posteriormente, estas unidades se condensaron y agruparon en categorías y subcategorías comparables. La interpretación conservó el contexto en el que cada autor había definido la predicción, el abandono y la explicabilidad, evitando equiparar términos que respondieran a decisiones metodológicas diferentes. Cuando una evidencia no se ajustó a la estructura inicial, se registró como hallazgo emergente para impedir que el esquema deductivo eliminara contenidos pertinentes. La síntesis final se presentó narrativamente, apoyada en matrices comparativas, sin calcular tamaños de efecto ni producir estimaciones generalizables, porque el alcance correspondió a una comprensión exploratoria y descriptiva de la evidencia (Braun & Clarke, 2021; Kuckartz & Rädiker, 2023).

La consistencia analítica se procuró mediante definiciones explícitas de las categorías, reglas de inclusión de unidades textuales, conservación de fragmentos de evidencia y registro de las decisiones tomadas durante la codificación. También se contrastaron las interpretaciones con la pregunta y los objetivos del estudio para evitar que la revisión se desplazara hacia aplicaciones de inteligencia artificial ajenas al abandono universitario. La credibilidad dependió de la trazabilidad entre documentos, códigos, categorías e interpretación final, mientras que la reflexividad exigió reconocer que la selección y lectura de la evidencia estuvieron mediadas por decisiones del equipo investigador. En consecuencia, los resultados describieron tendencias y brechas de la literatura seleccionada, pero no validaron la eficacia real de un modelo predictivo ni demostraron que las explicaciones generaran intervenciones institucionales exitosas. Esta delimitación fue necesaria para mantener congruencia entre el alcance cualitativo-documental y las conclusiones que podían sostenerse con el material examinado (Flick, 2022; Kuckartz & Rädiker, 2023).

Las consideraciones éticas se centraron en el uso responsable de documentos publicados, la atribución precisa de las ideas y la protección de cualquier información sensible reproducida en las fuentes. Al no haberse establecido contacto con participantes ni utilizado expedientes académicos individualizados, el estudio no implicó reclutamiento, intervención educativa o tratamiento directo de datos personales; sin embargo, se mantuvo una evaluación crítica de los riesgos éticos descritos por los trabajos revisados. Se examinó especialmente si los modelos podían reforzar desigualdades, presentar correlaciones como causas, etiquetar prematuramente a estudiantes o generar decisiones automatizadas sin supervisión profesional. Asimismo, se evitó interpretar la explicabilidad como una garantía suficiente de justicia, puesto que una explicación comprensible podía continuar sustentándose en datos sesgados o relaciones pedagógicamente débiles. El uso de

la evidencia se limitó a los fines académicos de análisis, síntesis y citación, manteniendo la transparencia y la responsabilidad humana como criterios centrales de la analítica educativa (Khosravi et al., 2022; Morgan, 2022).

3. Resultados

3.1. Factores asociados y patrones de riesgo del abandono universitario en entornos híbridos

El análisis respondió al objetivo específico de examinar la relación entre las variables socioeconómicas, académicas, institucionales y de interacción digital y la ocurrencia del abandono universitario. Dentro del corpus documental, el mapa regional de mayor amplitud reunió 217 estudios publicados entre 1992 y 2022, de los cuales 164 —el 76 %— se concentraron en el abandono y 53 —el 24 %— en la permanencia. El resumen de dicho estudio informó 67 variables, mientras que su sección analítica detalló 64; por esta razón, se conservaron los recuentos desagregados incluidos en las tablas de resultados. De manera complementaria, una revisión latinoamericana reciente incorporó 21 estudios y clasificó los factores en dimensiones académicas, individuales, económicas e institucionales (Chiarino et al., 2024; Ramirez Heredia & Carcausto-Calla, 2024).

La distribución por niveles mostró una concentración marcada en las características del estudiantado, consideradas en 202 de los 217 documentos, equivalentes al 93,1 % del corpus regional. Los factores institucionales estuvieron presentes en 115 estudios —53,0 %—, mientras que 70 trabajos —32,3 %— incorporaron variables del sistema educativo y nueve —4,1 %— abordaron condiciones macrosociales. Debido a que un mismo estudio pudo analizar más de un nivel o dimensión, estas proporciones no fueron mutuamente excluyentes y su suma superó el 100 %. Como se observa en la Tabla 1, las dimensiones académica, socioeconómica y psicológica registraron las mayores frecuencias, seguidas por las condiciones institucionales y las ayudas económicas del sistema educativo (Chiarino et al., 2024).

Tabla 1
Distribución de los factores asociados al abandono y la permanencia universitaria

Nivel sistémico	Estudios, <i>n</i>	% del corpus	Dimensiones o variables con mayor frecuencia, <i>n</i>
Sujeto	202	93,1	Académica (134), sociodemográfica (126), socioeconómica (116) y psicológica (112)
Institucional	115	53,0	Condiciones de estudio (69), aula (55), plan de estudios (55) y estrategias de permanencia (41)
Sistema educativo	70	32,3	Becas y ayudas económicas (53), accesibilidad territorial (17), políticas educativas (17) y presupuesto (8)
Macrosocial	9	4,1	Crisis macroeconómicas (4), pandemia (3) e inseguridad (3)

Nota: Los porcentajes fueron calculados sobre 217 estudios y pudieron superar conjuntamente el 100 % porque cada documento abordó varias dimensiones. Las frecuencias correspondieron a la tabla

analítica del estudio fuente; en ella se registraron 69 trabajos sobre condiciones de estudio, aunque la descripción narrativa posterior informó 70. Elaboración basada en Chiarino et al. (2024).

La dimensión académica fue la categoría más frecuente, pues apareció en 134 estudios —61,8 % del corpus— y se concentró principalmente en el desempeño durante la trayectoria universitaria. Esta variable estuvo presente en 93 trabajos —42,9 %—, mientras que 26 examinaron los créditos aprobados, 22 registraron dificultades para avanzar en la carrera, 18 analizaron el tiempo de estudio y 17 abordaron el rezago universitario. Entre los 114 documentos que analizaron la trayectoria en educación superior, 100 estuvieron orientados al abandono y 14 a la permanencia. El patrón descrito vinculó el abandono temprano con el bajo desempeño en los primeros años, el avance académico insuficiente, la discontinuidad educativa y las dificultades de adaptación a las exigencias universitarias (Chiarino et al., 2024).

Junto con el rendimiento académico, la dimensión socioeconómica se registró en 116 artículos —53,5 %—, de los cuales 101 estudiaron el abandono y 15 la permanencia. Los ingresos del hogar constituyeron la variable económica más examinada, con presencia en 98 documentos —45,2 % del corpus—, seguidos por las condiciones de trabajo en 59 —27,2 %— y el desempleo en tres. Los estudiantes procedentes de hogares con menores ingresos y quienes combinaron trabajo y estudios mostraron una mayor frecuencia de abandono, especialmente cuando los horarios académicos fueron incompatibles con la actividad laboral. El costo de la matrícula o de estudiar apareció en 12 artículos y las becas en 53, aunque las fuentes no proporcionaron valores monetarios homogéneos que permitieran presentar medias, montos en euros o variaciones financieras comparables (Chiarino et al., 2024).


Las características sociodemográficas configuraron un segundo conjunto de patrones recurrentes. El género fue examinado en 70 estudios, el lugar de residencia en 49, la edad de ingreso en 48, la estructura familiar en 39 y la formación del padre o de la madre en 38. La mayoría de los documentos que desagregaron los resultados por género registró mayor abandono entre los hombres, aunque algunos campos formativos presentaron una dirección diferente. La mayor edad al ingreso, la residencia alejada de la institución y el traslado desde la ciudad de origen aparecieron asociados con una menor continuidad. Asimismo, 17 estudios relacionaron las responsabilidades de cuidado con el abandono, diez consideraron el embarazo y otros diez registraron problemas de salud como antecedentes de la interrupción académica (Chiarino et al., 2024).

El componente psicológico estuvo presente en 112 estudios —51,6 % del corpus— y mostró una concentración en cuatro variables: motivación, orientación vocacional, creencias sobre la carrera y autorregulación del aprendizaje. La motivación y la orientación vocacional fueron abordadas en 44 documentos cada una, mientras que 41 examinaron las expectativas o representaciones acerca de la carrera y 22 registraron los hábitos de estudio, la gestión del tiempo o las estrategias autorregulatorias. La falta de motivación, la elección vocacional poco consolidada y la discrepancia entre las expectativas iniciales y la experiencia universitaria estuvieron

asociadas con el abandono. Otros 11 trabajos incorporaron el compromiso académico y la salud mental, mientras que nueve analizaron las emociones académicas; estas últimas variables presentaron menor frecuencia y una operacionalización más heterogénea (Chiarino et al., 2024).

La evidencia específica de educación en línea e híbrida agregó cinco categorías relacionadas con el componente digital. En una revisión de 110 artículos, los factores motivacionales representaron 15 de los 59 factores identificados —25,4 %—; los relacionados con el curso reunieron 12 —20,3 %—; los tecnológicos y demográficos incluyeron 11 cada uno —18,6 %—; y los vinculados con el apoyo sumaron diez —16,9 %—. El diseño, la organización y el contenido del curso aparecieron en 31 estudios, la satisfacción y el logro académico en 21, la motivación en 19 y la autorregulación y las actividades de estudio en línea en 13 cada una. La calidad del sistema y la conectividad a Internet fueron registradas en 11 trabajos respectivamente, mientras que los problemas tecnológicos aparecieron en ocho (Rahmani et al., 2024).

Figura 1
Patrones de riesgo del abandono universitario en entornos híbridos



Nota: (Autores, 2026).

La representación integró variables que operaron simultáneamente y mostró que las mayores frecuencias no correspondieron exclusivamente a atributos personales. El ingreso familiar y el desempeño académico coaparecieron dentro del nivel del estudiante, mientras que las estrategias pedagógicas y la motivación conectaron los niveles institucional e individual. En los entornos híbridos, la participación digital también estuvo relacionada con la conectividad, la calidad del sistema, el diseño del curso y la disponibilidad de tiempo para estudiar. Por tanto, una reducción de accesos a la plataforma no constituyó por sí misma un patrón suficiente de abandono, sino que formó parte de configuraciones que incluyeron rendimiento, trabajo, motivación y condiciones institucionales. Los mapas de coocurrencia descartaron las relaciones registradas en menos de cinco documentos, conservando únicamente los patrones de mayor reiteración (Chiarino et al., 2024; Rahmani et al., 2024).

El hallazgo central quedó definido por la acumulación de riesgos académicos, económicos, psicológicos, institucionales y tecnológicos, antes que por la presencia aislada de una variable. El predominio del nivel sujeto —93,1 %— coexistió con una participación considerable del nivel institucional —53,0 %— y del sistema educativo —32,3 %—, mientras que los factores macrosociales fueron menos estudiados —4,1 %—. En la modalidad híbrida, los indicadores de actividad digital adquirieron sentido al relacionarse con el diseño del curso, la motivación, el apoyo docente y el acceso tecnológico. Los documentos revisados no ofrecieron medias, desviaciones estándar, intervalos de confianza o valores p comparables para el conjunto de variables, por lo que la síntesis se limitó a frecuencias, porcentajes y direcciones de asociación expresamente reportadas (Chiarino et al., 2024; Ramirez Heredia & Carcausto-Calla, 2024; Rahmani et al., 2024).

2. Desempeño predictivo, explicabilidad y equidad de los modelos analizados

El subapartado respondió a los objetivos de determinar el desempeño predictivo de los modelos, comparar las explicaciones globales y locales y describir la evaluación de calibración y equidad. La síntesis se sustentó en un corpus de 75 estudios sobre predicción del abandono universitario publicados entre 2019 y 2024, seleccionados a partir de 301 registros inicialmente identificados. Debido al carácter documental de la investigación, no se entrenó un modelo regional nuevo ni se calcularon métricas adicionales sobre expedientes estudiantiles. Los resultados correspondieron, por tanto, a los indicadores comunicados por las investigaciones primarias y a las frecuencias consolidadas por la revisión examinada. Esta delimitación mantuvo la correspondencia con los objetivos formulados en el documento compartido y permitió diferenciar el rendimiento predictivo, la explicación de las decisiones y la evaluación entre grupos (Khosravi et al., 2022; Lopez-Muñoz et al., 2026).

La distribución de los algoritmos mostró que los estudios probaron con mayor frecuencia bosques aleatorios, regresión logística, árboles de decisión y XGBoost. Los bosques aleatorios aparecieron en 61 de los 75 trabajos —81,3 %—, mientras que la regresión logística se utilizó en 47 —62,7 %— y los árboles de decisión en 43 —57,3

%—. XGBoost se registró en 34 investigaciones —45,3 %— y los métodos de *stacking* en 16 —21,3 %—. Un mismo documento pudo evaluar varios algoritmos, de modo que las frecuencias no constituyeron categorías excluyentes. Como se observa en la Tabla 2, las exactitudes medias más elevadas se concentraron en los métodos de ensamble, aunque la disponibilidad de métricas no fue uniforme en todos los estudios (Lopez-Muñoz et al., 2026).

Tabla 2

Frecuencia de utilización y exactitud media de los modelos predictivos analizados

Modelo predictivo	Estudios, <i>n</i>	Estudios, %	Exactitud media reportada, %
Bosque aleatorio	61	81,3	86,2
Regresión logística	47	62,7	79,3
Árboles de decisión	43	57,3	81,4
XGBoost	34	45,3	87,4
<i>Gradient boosting</i>	21	28,0	84,5
Máquina de vectores de soporte	19	25,3	80,1
Naive Bayes	18	24,0	76,2
<i>Stacking ensemble</i>	16	21,3	88,1
Clasificador por votación	8	10,7	85,3

Nota: Las frecuencias y los porcentajes superaron conjuntamente el total del corpus porque cada estudio pudo comparar varios algoritmos. La exactitud media correspondió a la síntesis comunicada por la revisión y no representó un metaanálisis ponderado por tamaño muestral (Lopez-Muñoz et al., 2026) (Autores, 2026).

La comparación descriptiva confirmó una variación de 11,9 puntos porcentuales entre la menor y la mayor exactitud media consignada en la Tabla 2. El método de *stacking* alcanzó el valor más alto, con 88,1 %, seguido de XGBoost con 87,4 %, bosque aleatorio con 86,2 % y clasificación por votación con 85,3 %. Entre los algoritmos individuales, los árboles de decisión registraron 81,4 %, las máquinas de vectores de soporte 80,1 % y la regresión logística 79,3 %. Naive Bayes presentó la exactitud media más baja, equivalente al 76,2 %. Las redes neuronales basadas en arquitecturas LSTM o CNN se situaron entre 82 % y 86 %, aunque su heterogeneidad impidió integrarlas en una única categoría comparable con los nueve modelos de la tabla (Lopez-Muñoz et al., 2026).


La evaluación temporal realizada en una institución europea aportó resultados adicionales sobre discriminación y calibración a partir de 8.508 registros estudiantiles. El conjunto de entrenamiento estuvo compuesto por 6.398 observaciones correspondientes a las cohortes de 2013 a 2016, mientras que la prueba temporal reunió 2.110 casos de la cohorte de 2017. CatBoost obtuvo una precisión media de 0,847 y un área bajo la curva de 0,774; la regresión logística alcanzó 0,799 y 0,734, respectivamente. La proporción de graduación fue de 65 % en el conjunto de entrenamiento y de 63 % en el conjunto de prueba. La calibración se examinó mediante métodos isotónico y sigmoidal, y el procedimiento isotónico produjo una separación más definida entre los grupos de probabilidad estimada (Nagy & Molontay, 2024).

La dimensión de explicabilidad estuvo menos extendida que la evaluación de exactitud, pues aproximadamente el 24 % de los 75 estudios incorporó técnicas explícitas de XAI. Los procedimientos registrados comprendieron importancia por permutación, gráficos de dependencia parcial y valores SHAP para la explicación global, junto con SHAP y LIME para justificar predicciones individuales. En el estudio de CatBoost, las variables de mayor contribución fueron el promedio de educación secundaria, el desempeño en matemáticas, la asignatura elegida y el intervalo entre la finalización escolar y el ingreso universitario. La evaluación de las representaciones explicativas incluyó a diez responsables de educación superior y 42 estudiantes. En una escala de cinco puntos, las medias alcanzaron 4,2 para interpretabilidad, 4,4 para utilidad y 4,8 para calidad estética, mientras los gráficos de barras fueron valorados como más fáciles de comprender que los diagramas de fuerza (Khosravi et al., 2022; Nagy & Molontay, 2024).

El examen específico de un curso universitario híbrido incorporó 126 estudiantes y comparó bosque aleatorio, XGBoost, red neuronal, regresión lineal y máquina de vectores de soporte. Los registros se dividieron en 70 % para entrenamiento y 30 % para prueba, preservando la separación entre las dos fases de modelización. El bosque aleatorio presentó el menor error cuadrático medio, raíz del error cuadrático medio y desviación absoluta media, además del mayor coeficiente de determinación entre los cinco algoritmos. Las calificaciones formativas ocuparon el primer nivel de importancia, seguidas por la publicación de aportes, la consulta de instrucciones y el acceso a recursos de aprendizaje. Los foros de apoyo, la socialización, el número de días activos, la duración de las sesiones y la navegación por cuestionarios mostraron una contribución comparativamente menor (Saqr & López-Pernas, 2024).

Figura 2

Matriz de evaluación de modelos de abandono universitario



Nota: (Autores, 2026).

La matriz visual organizó los resultados en cuatro niveles que no aparecieron evaluados con igual frecuencia en el corpus. El rendimiento se documentó mediante

exactitud, precisión media, AUC y medidas de error, mientras que la explicabilidad se concentró en una proporción menor de estudios. La calibración se comunicó de manera específica en algunos modelos, pero no se encontró una serie homogénea que permitiera calcular una media conjunta. La equidad se examinó principalmente mediante la composición de las bases, el tratamiento del desequilibrio de clases y la presencia de variables sociodemográficas. En conjunto, 68 % de los trabajos utilizó información procedente de una sola institución, 64 % reconoció problemas de transferencia y 42 % no incorporó la evolución temporal de las trayectorias (Lopez-Muñoz et al., 2026).

La revisión de las predicciones individuales reveló diferencias que no quedaron reflejadas por las métricas agregadas del mejor modelo. Seis de los 126 estudiantes del curso híbrido presentaron errores superiores a diez puntos porcentuales entre la calificación estimada y la observada. En este grupo, la puntuación predicha alcanzó una media de 60,5 puntos y una desviación estándar de 5,1, mientras que la calificación real registró una media de 44,8 y una desviación estándar de 6,7. En un caso, el modelo estimó 69,66 puntos frente a un resultado real de 57; en otro, predijo 59 puntos frente a una calificación de 39. Las explicaciones locales de estos errores se apoyaron con frecuencia en indicadores de participación pasiva y algunas curvas de recomendación permanecieron prácticamente planas ante posibles modificaciones de la actividad digital (Saqr & López-Pernas, 2024).

El análisis de equidad mostró que menos del 10 % de las investigaciones incorporó variables interseccionales capaces de representar vulnerabilidades combinadas por género, condición socioeconómica, pertenencia étnica u otras características. El desequilibrio entre estudiantes que abandonaron y quienes permanecieron fue tratado explícitamente en el 71 % de los estudios mediante remuestreo, ponderación de clases o generación sintética de observaciones. Sin embargo, el mismo porcentaje del corpus finalizó en la etapa de predicción y no comunicó una validación empírica de intervenciones derivadas de las alertas. Tampoco se obtuvo una matriz comparable de diferencias de sensibilidad, falsos positivos, calibración o puntuación F1 entre grupos sociodemográficos y programas universitarios. El hallazgo central quedó caracterizado, por tanto, por un desempeño predictivo agregado elevado —especialmente entre los ensambles— y una cobertura documental menor de la explicabilidad, la calibración, la equidad y la transferencia entre contextos (Lopez-Muñoz et al., 2026).

4. Discusión

Los hallazgos permiten interpretar el abandono universitario en entornos híbridos como un proceso configurado por la acumulación de condiciones académicas, socioeconómicas, psicológicas, institucionales y tecnológicas, en correspondencia con el objetivo de identificar los factores que sostienen el riesgo. Aunque el 93,1 % de los estudios regionales examina variables del estudiante, la presencia de factores

institucionales en el 53,0 % y del sistema educativo en el 32,3 % impide reducir el fenómeno al rendimiento o a la motivación individual. Esta estructura coincide con la perspectiva ecológica de Chiarino et al. (2024) y con la clasificación multidimensional formulada por Ramirez Heredia y Carcausto-Calla (2024). A su vez, la evidencia sobre educación digital confirma que la conectividad, el diseño del curso y el apoyo docente modifican el significado de las huellas registradas en las plataformas. Por consiguiente, una disminución de accesos o entregas sugiere riesgo únicamente cuando se interpreta junto con la trayectoria académica, la situación económica y las condiciones de participación del estudiante (Rahmani et al., 2024; Saqr et al., 2017).

La comparación de los modelos muestra que los métodos de ensamble alcanzan exactitudes agregadas cercanas al 86–88 %, pero esta ventaja predictiva no se acompaña de una evaluación equivalente de explicabilidad, calibración y equidad. El hecho de que solo alrededor del 24 % de los estudios utilice técnicas explícitas de inteligencia artificial explicable converge con Khosravi et al. (2022), quienes señalan que una explicación educativa debe atender tanto al funcionamiento del algoritmo como a las necesidades de sus destinatarios. Los resultados de Nagy y Molontay (2024) respaldan la utilidad de combinar explicaciones globales y locales, aunque también evidencian que su comprensión depende del formato de presentación y de la experiencia del usuario. En contraste, los errores superiores a diez puntos identificados en seis de 126 estudiantes muestran que una buena métrica global puede ocultar predicciones individuales considerablemente desviadas. Este patrón coincide con Saqr y López-Pernas (2024), para quienes la explicabilidad no garantiza que los predictores utilizados sean pedagógicamente plausibles ni que las recomendaciones resultantes sean efectivas.

Las implicaciones metodológicas indican que la evaluación de un sistema de alerta no debería descansar exclusivamente en la exactitud, sino integrar discriminación, sensibilidad, calibración, estabilidad temporal, interpretabilidad y distribución de errores entre grupos. Esta necesidad adquiere relevancia práctica porque el 68 % de los trabajos utiliza datos de una sola institución, el 64 % reconoce limitaciones de transferencia y menos del 10 % incorpora variables interseccionales, lo que restringe la aplicación de los modelos a poblaciones latinoamericanas heterogéneas (Lopez-Muñoz et al., 2026). En términos institucionales, las predicciones podrían orientar tutorías, apoyos académicos o ayudas económicas, pero requieren supervisión humana y no deben transformarse en decisiones automáticas o etiquetas permanentes (Khosravi et al., 2022; Pardo & Siemens, 2014). Estos resultados deben interpretarse con cautela porque el estudio adopta un diseño cualitativo, documental y transversal, depende de métricas reportadas de manera heterogénea y no entrena ni valida un modelo con datos primarios. En consecuencia, las asociaciones sintetizadas describen patrones recurrentes, pero no permiten establecer causalidad, estimar efectos conjuntos ni confirmar la eficacia de las intervenciones derivadas de las alertas (Flick, 2022; Morgan, 2022).

La continuidad de esta línea exige estudios longitudinales y multicéntricos que integren universidades, programas y modalidades híbridas de distintos países latinoamericanos, con definiciones comparables de abandono y periodos de seguimiento suficientemente amplios. También resulta necesario contrastar modelos de ensamble con alternativas interpretables, evaluar la estabilidad de las explicaciones globales y locales y comunicar sensibilidad, falsos positivos y calibración de manera desagregada por género, condición socioeconómica y pertenencia étnica. La validación futura debería avanzar desde la predicción hacia intervenciones controladas, de modo que se determine si las alertas explicables mejoran efectivamente la permanencia sin producir estigmatización o asignación inequitativa de recursos (Lopez-Muñoz et al., 2026; Nagy & Molontay, 2024). En este marco, la principal contribución del estudio consiste en vincular la naturaleza multicausal del abandono con una evaluación más amplia de los modelos, donde rendimiento, explicación, calibración y equidad constituyen dimensiones complementarias. Así, se atiende la brecha regional identificada al proponer que las huellas digitales se conviertan en información preventiva contextualizada, comprensible y revisable, y no únicamente en probabilidades técnicamente precisas (Chiarino et al., 2024; Khosravi et al., 2022).

5. Conclusiones

Dentro del alcance cualitativo, documental y transversal adoptado, los resultados permiten concluir que una analítica del aprendizaje explicable orientada a predecir el abandono universitario debe integrar información académica, socioeconómica, psicológica, institucional y digital. Las huellas generadas en los entornos híbridos no constituyen indicadores suficientes cuando se interpretan de manera aislada, porque adquieren significado al relacionarse con la trayectoria y las condiciones de participación del estudiante. Los modelos de ensamble presentan un desempeño predictivo agregado elevado, cercano al 86–88 %, pero esta precisión no garantiza explicaciones pertinentes ni decisiones institucionales justas. Por ello, el objetivo general se alcanza en términos de sistematización de criterios para el desarrollo y evaluación del modelo, no como validación empírica de una herramienta regional ya implementada. Esta precisión resulta necesaria para mantener las conclusiones dentro del alcance real del estudio.

En relación con los objetivos específicos, los hallazgos evidencian que el abandono se configura mediante la acumulación de riesgos y no por una variable única o una secuencia causal demostrada. Las condiciones del estudiante concentran la mayor atención de la literatura, aunque los factores institucionales, tecnológicos y del sistema educativo también explican diferencias relevantes en la continuidad universitaria. Asimismo, los métodos predictivos más complejos superan descriptivamente a varios algoritmos tradicionales, pero la explicabilidad se incorpora apenas en una proporción reducida de las investigaciones analizadas. La calibración, la estabilidad temporal y la

equidad tampoco se evalúan con la misma consistencia que la exactitud, especialmente entre grupos sociodemográficos, programas y modalidades educativas. En conjunto, esto sugiere que predecir, explicar e intervenir constituyen procesos relacionados, pero metodológicamente distintos.

A partir de esta integración, el aporte principal del estudio consiste en proponer una lectura multidimensional de la analítica explicable que combina rendimiento predictivo, interpretación global y local, calibración, equidad y posibilidad de transferencia. Esta perspectiva amplía el valor académico de los modelos al vincular las métricas computacionales con la comprensión pedagógica del abandono. En el plano institucional, los sistemas de alerta podrían apoyar la asignación oportuna de tutorías, orientación académica y ayudas económicas, siempre que sus resultados sean revisados por equipos responsables. También se observa que una explicación comprensible no debe asumirse como garantía de justicia, debido a que puede reproducir sesgos presentes en los datos o apoyarse en variables poco plausibles. La contribución se concentra, por tanto, en orientar el uso preventivo y contextualizado de la información sin convertir las predicciones en etiquetas permanentes.

La investigación futura debería validar estos criterios mediante estudios longitudinales y multicéntricos que incorporen universidades, carreras y poblaciones diversas de América Latina. Resultaría pertinente comparar modelos interpretables y de ensamble mediante métricas homogéneas de discriminación, sensibilidad, calibración y distribución de falsos positivos entre grupos sociales. También sería necesario evaluar la estabilidad de las explicaciones durante distintos periodos académicos e integrar variables interseccionales que permitan representar desigualdades acumuladas. Las alertas deberían someterse posteriormente a evaluaciones de intervención para determinar si contribuyen a la permanencia sin producir estigmatización ni asignaciones inequitativas de recursos. De este modo, la principal contribución de la investigación reside en establecer que la utilidad de la analítica explicable depende de articular precisión técnica, sentido educativo y responsabilidad institucional frente al abandono universitario.

CONFLICTO DE INTERESES

“Los autores declaran no tener ningún conflicto de intereses”.

Referencias Bibliográficas

Alyahyan, E., & Düşteğör, D. (2020). Predicting academic success in higher education: Literature review and best practices. *International Journal of Educational Technology in Higher Education*, 17, Article 3. <https://doi.org/10.1186/s41239-020-0177-7>

- Braun, V., & Clarke, V. (2021). *Thematic analysis: A practical guide*. SAGE Publications. <https://uk.sagepub.com/en-gb/eur/thematic-analysis/book248481>
- Chiarino, N., Rodríguez Enríquez, C., Curione, K., Machado, A., Bonilla, M., Aspirot, L., Garófalo, L., & Oliveira, B. (2024). Abandono y permanencia estudiantil en universidades de Latinoamérica y el Caribe: Una revisión sistemática mixta. *Actualidades Investigativas en Educación*, 24(2), 1–37. <https://doi.org/10.15517/aie.v24i2.57306>
- Escobar-Terán, H. E., Mendoza-Vargas, E. Y., Cedeño-Salazar, B. C., & Castillo-Plaza, I. A. (2025). Educación superior inclusiva y diversidad funcional: caracterización multidimensional en la Universidad Técnica Estatal de Quevedo. *Revista Científica Ciencia Y Método*, 3(4), 470-489. <https://doi.org/10.55813/gaea/rcym/v3/n4/124>
- Ferreira, M. M., Avitabile, C., Botero Álvarez, J., Haimovich Paz, F., & Urzúa, S. (2017). *At a crossroads: Higher education in Latin America and the Caribbean*. World Bank. <https://doi.org/10.1596/978-1-4648-1014-5>
- Flick, U. (2022). *An introduction to qualitative research* (7.^a ed.). SAGE Publications. <https://uk.sagepub.com/en-gb/eur/an-introduction-to-qualitative-research/book278983>
- Heredia, R. C. R., & Carcausto-Calla, W. (2024). Factors associated with student dropout in Latin American universities: Scoping review. *Journal of Educational and Social Research*, 14(2), 63–72. <https://doi.org/10.36941/jesr-2024-0026>
- Herrera-Acosta, C. E., Rodríguez-Borja, P. A., Tituaña-Andrade, E. N., López-Torres, A., & Defranc-Roca, S. (2026). Equidad e inclusión: análisis de las políticas públicas para el acceso a salud, educación y trabajo de los grupos de atención prioritaria. *Revista Científica Zambos*, 5(1), 97-115. <https://doi.org/10.69484/rcz/v5/n1/155>
- Herrera-Irazábal, E. G., Macías-Moreira, E. M., & Vinueza-Morales, M. G. (2026). Uso de las metodologías activas y su relación con la innovación educativa en estudiantes universitarios. *Revista Científica Ciencia Y Método*, 4(2), 160-175. <https://doi.org/10.55813/gaea/rcym/v4/n2/188>
- Inter-American Development Bank. (2021). *Higher education digital transformation in Latin America and the Caribbean*. <https://publications.iadb.org/publications/english/document/Higher-Education-Digital-Transformation-in-Latin-America-and-the-Caribbean.pdf>
- JB. (2024). *JB manual for evidence synthesis*. <https://jbi-global.atlassian.net/wiki/spaces/MANUAL>
- Khosravi, H., Shum, S. B., Chen, G., Conati, C., Tsai, Y.-S., Kay, J., Knight, S., Martinez-Maldonado, R., Sadiq, S., & Gašević, D. (2022). Explainable artificial intelligence in education. *Computers and Education: Artificial Intelligence*, 3, Article 100074. <https://doi.org/10.1016/j.caeai.2022.100074>
- Kuckartz, U., & Rädiker, S. (2023). *Qualitative content analysis: Methods, practice and software* (2.^a ed.). SAGE Publications. <https://www.sagepub.com/shop/buy-a-book/qualitative-content-analysis-2-282907>

- Lopez-Muñoz, G. L., Gonzalez Serrano, C., & Sanchez-Ferreira, C. (2026). Student dropout prediction in higher education: A systematic review of machine learning methods and risk factors. *Journal of Information Technology Education: Research*, 25, Article 20. <https://doi.org/10.28945/5776>
- López-Sánchez, J. A., Morales-Chincha, J. A., Echeverri-Ocampo, C. D., & Hernández-Ortiz, J. (2025). Articulación Universidad, Empresa y Estado, en ecosistemas de ciencia, tecnología, innovación: revisión sistemática con metodología prisma. *Journal of Economic and Social Science Research*, 5(3), 28-47. <https://doi.org/10.55813/gaea/jessr/v5/n3/201>
- Morgan, H. (2022). Conducting a qualitative document analysis. *The Qualitative Report*, 27(1), 64–77. <https://doi.org/10.46743/2160-3715/2022.5044>
- Nagy, M., & Molontay, R. (2024). Interpretable dropout prediction: Towards XAI-based personalized intervention. *International Journal of Artificial Intelligence in Education*, 34, 274–300. <https://doi.org/10.1007/s40593-023-00331-8>
- Pardo, A., & Siemens, G. (2014). Ethical and privacy principles for learning analytics. *British Journal of Educational Technology*, 45(3), 438–450. <https://doi.org/10.1111/bjet.12152>
- 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, Article 19. <https://doi.org/10.1186/s41239-024-00450-9>
- Ramirez Heredia, R. C., & Carcausto-Calla, W. (2024). Factors associated with student dropout in Latin American universities: Scoping review. *Journal of Educational and Social Research*, 14(2), 62–72. <https://doi.org/10.36941/jesr-2024-0026>
- Samueza-Umaquinga, M. C., Medina-Macas, L. H., Padilla-Sevillano, J. A., Lema-Pillajo, D. A., & Miranda-Asto, V. R. (2025). El impacto del Diseño Universal para el Aprendizaje en la implementación de metodologías activas con apoyo tecnológico. *Revista Científica Ciencia Y Método*, 3(4), 41-53. <https://doi.org/10.55813/gaea/rcym/v3/n4/91>
- Santos-Vera, P. Y., Campo-Yanez, M. G., Erazo-Loor, D. J., Oña-Suquillot, K. B., & Mejia-Villacres, S. E. (2026). Inserciones escolares como estrategia de adaptación curricular: evaluación de un modelo basado en DUA en aulas diversas. *Revista Científica Zambos*, 5(1), 67-80. <https://doi.org/10.69484/rcz/v5/n1/151>
- Saqr, M., & López-Pernas, S. (2024). Why explainable AI may not be enough: Predictions and mispredictions in decision making in education. *Smart Learning Environments*, 11, Article 52. <https://doi.org/10.1186/s40561-024-00343-4>
- Saqr, M., Fors, U., & Tedre, M. (2017). How learning analytics can early predict under-achieving students in a blended medical education course. *Medical Teacher*, 39(7), 757–767. <https://doi.org/10.1080/0142159X.2017.1309376>
- Suárez-González, S. O., Rodriguez-Moreano, R. P., Tobar-Rogel, M. F., Alvarez-Ayala, D. M., & Castro-Sánchez, N. G. (2026). La integración de tecnologías emergentes como IA y realidad virtual y su efecto en la motivación y el

- rendimiento de los estudiantes. *Revista Científica Zambos*, 5(1), 81-96. <https://doi.org/10.69484/rcz/v5/n1/152>
- Torres Roberto, M. A. (2021). *Enseñanza y aprendizaje de la geometría en 3.º ESO a través de la metodología taller educativo* [Trabajo de fin de máster, Universidad Internacional de La Rioja]. ResearchGate. <https://doi.org/10.13140/RG.2.2.24355.16163>
- Torres Roberto, M. A. (2024). *Evaluación formativa continua en la educación matemática: Enfoques en la enseñanza y aprendizaje del cálculo en educación superior*. Generis Publishing. <https://generis-publishing.com/book.php?title=strong-evaluacin-formativa-continua-en-la-educacin-matemtica-strong-2356>
- Torres Roberto, M. A. (2025). Estrategias de aprendizaje y factores emocionales en Cálculo Diferencial: Experiencias del estudiantado de ingeniería en Colombia. *Revista Actualidades Investigativas en Educación*, 25(2), 1-34. <https://doi.org/10.15517/aie.v25i2.62607>
- Vimos-Buenaño, K. E., Viteri-Ojeda, J. C., Naranjo-Sánchez, M. J., & Novillo-Heredia, K. H. (2024). Uso de la inteligencia artificial en los procesos de investigación científica, por parte de los docentes universitarios. *Journal of Economic and Social Science Research*, 4(4), 215–236. <https://doi.org/10.55813/gaea/jessr/v4/n4/143>
- Vinza-Coronel, C. G., Plúa-Panta, K. A., & Tenelema-Jiménez, I. E. (2026). Reconocimiento organizacional y su relación con la satisfacción laboral en el personal de servicios de una institución universitaria. *Journal of Economic and Social Science Research*, 6(2), 101-112. <https://doi.org/10.55813/gaea/jessr/v6/n2/243>