



Learning analytics to predict performance and dropout risk in higher education

Analítica del aprendizaje para predecir rendimiento y riesgo de abandono en educación superior

Freddy Leonardo Garaicoa Fuentes¹  

¹ Universidad Estatal de Milagro, Milagro, Ecuador

Recibido: 14-08-2025 | Revisado: 01-09-2025 | Aceptado: 29-11-2025 | Publicado: 7-12-2025

Autor de correspondencia: Freddy Leonardo Garaicoa Fuentes 

ABSTRACT

Introduction: Analítica del aprendizaje para predecir rendimiento y riesgo de abandono en educación superior is an emerging higher-education issue related to measurement quality, decision-making and learning experience. **Objective:** To systematically synthesize available evidence and identify patterns of effectiveness, methodological quality and implementation conditions. **Method:** A PRISMA-oriented systematic review was conducted on a consolidated academic corpus of 135 records; 5 studies met relevance and documentary sufficiency criteria. **Results:** Evidence was methodologically heterogeneous but converged on the need to align technology, constructs, feedback and educational decisions. **Conclusions:** Findings support evidence-informed adoption, institutional monitoring and continuous assessment of validity, equity and utility.

Keywords: higher education; systematic review; educational assessment; evidence; PRISMA; educational technology.

RESUMEN

Introducción: Analítica del aprendizaje para predecir rendimiento y riesgo de abandono en educación superior representa un problema emergente para la educación superior por su relación con la calidad de la medición, la toma de decisiones y la experiencia de aprendizaje. **Objetivo:** sintetizar sistemáticamente la evidencia disponible y establecer patrones de efectividad, calidad metodológica y condiciones de implementación. **Método:** se aplicó una revisión sistemática con lógica PRISMA sobre un corpus académico consolidado de 135 registros, del cual se incluyeron 5 estudios que cumplieron criterios de pertinencia y suficiencia documental. **Resultados:** la evidencia muestra heterogeneidad de diseños y contextos, junto con convergencias en torno a la necesidad de alinear tecnología, constructo, retroalimentación y decisiones educativas. **Conclusiones:** los resultados respaldan una adopción basada en evidencia, seguimiento institucional y evaluación continua de validez, equidad y utilidad.

Palabras clave: educación superior; revisión sistemática; evaluación educativa; evidencia; PRISMA; tecnología educativa.

INTRODUCCIÓN

La investigación universitaria sobre analítica del aprendizaje para predecir rendimiento y riesgo de abandono en educación superior ha adquirido una relevancia creciente porque las decisiones de evaluación ya no dependen exclusivamente de instrumentos estáticos ni de intercambios presenciales. La digitalización ha ampliado la cantidad de evidencias disponibles sobre desempeño, interacción y aprendizaje, pero también ha incrementado la necesidad de distinguir entre innovaciones técnicamente atractivas y prácticas capaces de sostener inferencias educativas válidas. Esta revisión aborda ese problema desde una perspectiva integradora, interesada tanto en los efectos observados como en las condiciones metodológicas que permiten interpretar dichos efectos sin confundir disponibilidad tecnológica con calidad evaluativa.

El núcleo conceptual del manuscrito se organiza alrededor de predicción educativa. Esta elección evita tratar la literatura como una simple colección de resultados y permite examinar cómo cada estudio define el fenómeno, qué población observa, qué instrumentos emplea y qué tipo de conclusión considera legítima. La heterogeneidad de contextos universitarios obliga a prestar atención a la relación entre diseño, implementación y evidencia, porque una misma estrategia puede producir beneficios bajo determinadas condiciones y resultados modestos cuando cambian el soporte docente, la disciplina, la experiencia digital o la forma de retroalimentación.

La revisión sistemática resulta pertinente porque el campo combina estudios experimentales, validaciones instrumentales, análisis observacionales, desarrollos tecnológicos y síntesis previas. Esa diversidad dificulta obtener conclusiones sólidas mediante una lectura fragmentaria. En lugar de asumir que todos los trabajos responden a una misma pregunta, el presente artículo reconstruye patrones de convergencia y divergencia, identifica qué resultados se repiten con mayor consistencia y separa las afirmaciones directamente sustentadas por los estudios de aquellas que todavía requieren validación adicional. El propósito es ofrecer una lectura útil para investigación, docencia y gestión universitaria. Revisiones previas confirman la diversidad de enfoques, métodos y niveles de evidencia en analítica del aprendizaje en educación superior⁶⁻¹⁰.

Señales digitales, predicción y riesgo de abandono

Vaarma y Li¹ aportaron evidencia publicada en 2024 mediante estudio predictivo de machine learning. El estudio trabajó con Datos de una universidad finlandesa; expedientes, demografía y Moodle, lo que permite situar el alcance de sus inferencias y valorar su proximidad con la población universitaria de interés. En términos sustantivos, el trabajo mostró que los datos LMS resultaron potentes para predecir abandono; créditos, cursos fallidos y actividad Moodle fueron predictores importantes. Este antecedente es relevante para la perspectiva de predicción educativa porque muestra que la interpretación del efecto depende de la correspondencia entre constructo, procedimiento de medición y contexto de aplicación. Su contribución se considera en esta revisión como una pieza del patrón comparativo, no como una demostración aislada suficiente para generalizar a todos los escenarios educativos.

Niyogisubizo et al.² aportaron evidencia publicada en 2022 mediante modelado predictivo ensemble. El estudio trabajó con Datos universitarios 2016–2020 de Constantine the Philosopher University, lo que permite situar el alcance de sus inferencias y valorar su proximidad con la población universitaria de interés. En términos sustantivos, el trabajo mostró que el ensemble superó a modelos base en accuracy y AUC, permitiendo identificar estudiantes en riesgo para intervención temprana. Este antecedente es relevante para la perspectiva de predicción educativa porque muestra que la interpretación del efecto depende de la correspondencia entre constructo, procedimiento de medición y contexto de aplicación. Su contribución se considera en esta revisión como una pieza del patrón comparativo, no como una demostración aislada suficiente para generalizar a todos los escenarios educativos.

Ovtšarenko³ aportaron evidencia publicada en 2026 mediante learning analytics predictivo. El estudio trabajó con 99,104 registros de actividad de 154 estudiantes, lo que permite situar el alcance de sus inferencias y valorar su proximidad con la población universitaria de interés. En términos sustantivos, el trabajo mostró que los modelos identificaron estudiantes en riesgo y permitieron alertas tempranas y apoyo adaptativo. Este antecedente es relevante para la perspectiva de predicción educativa porque muestra que la interpretación del efecto depende de la correspondencia entre constructo, procedimiento de medición y contexto de aplicación. Su contribución se considera en esta revisión como una pieza del patrón comparativo, no como una demostración aislada suficiente para generalizar a todos los escenarios educativos.


Cannistrà et al.⁴ aportaron evidencia publicada en 2022 mediante modelado multinivel y machine learning. El estudio trabajó con Datos administrativos de una universidad italiana, lo que

permite situar el alcance de sus inferencias y valorar su proximidad con la población universitaria de interés. En términos sustantivos, el trabajo mostró que demostró viabilidad de un sistema de alerta temprana para identificar riesgo de abandono. Este antecedente es relevante para la perspectiva de predicción educativa porque muestra que la interpretación del efecto depende de la correspondencia entre constructo, procedimiento de medición y contexto de aplicación. Su contribución se considera en esta revisión como una pieza del patrón comparativo, no como una demostración aislada suficiente para generalizar a todos los escenarios educativos.

Choi y Johnson⁵ aportaron evidencia publicada en 2025 mediante estudio metodológico con simulación y datos reales. El estudio trabajó con conjunto de datos real, lo que permite situar el alcance de sus inferencias y valorar su proximidad con la población universitaria de interés. En términos sustantivos, el trabajo mostró que la medida identificó correctamente características responsables del sesgo en simulaciones y halló conjuntos consistentes de variables en datos reales. Este antecedente es relevante para la perspectiva de predicción educativa porque muestra que la interpretación del efecto depende de la correspondencia entre constructo, procedimiento de medición y contexto de aplicación. Su contribución se considera en esta revisión como una pieza del patrón comparativo, no como una demostración aislada suficiente para generalizar a todos los escenarios educativos.

Figura 1. Estructura conceptual de la revisión

Estructura conceptual de la revisión



Nota. Elaboración propia a partir de los ejes analíticos definidos para el manuscrito.

La figura organiza el razonamiento del artículo como una secuencia conceptual y no como una plantilla universal. Los componentes representados corresponden al problema específico de esta revisión y muestran el tránsito desde los insumos o condiciones iniciales hasta la interpretación educativa. Su utilidad consiste en hacer visible la relación entre constructos que, en los estudios individuales, suelen aparecer fragmentados entre secciones metodológicas y de resultados. Esta representación orienta la síntesis posterior y facilita distinguir los elementos que actúan como condiciones, mecanismos o resultados dentro del corpus.

Preguntas de revisión

Pregunta 1. ¿Qué patrones de evidencia permiten comprender la dimensión 1 de predicción educativa en relación con analítica del aprendizaje para predecir rendimiento y riesgo de abandono en educación superior y qué condiciones metodológicas o contextuales modifican su interpretación?

Pregunta 2. ¿Qué patrones de evidencia permiten comprender la dimensión 2 de predicción educativa en relación con analítica del aprendizaje para predecir rendimiento y riesgo de abandono en educación superior y qué condiciones metodológicas o contextuales modifican su interpretación?

Pregunta 3. ¿Qué patrones de evidencia permiten comprender la dimensión 3 de predicción educativa en relación con analítica del aprendizaje para predecir rendimiento y riesgo de abandono en educación superior y qué condiciones metodológicas o contextuales modifican su interpretación?

Pregunta 4. ¿Qué patrones de evidencia permiten comprender la dimensión 4 de predicción educativa en relación con analítica del aprendizaje para predecir rendimiento y riesgo de abandono en educación superior y qué condiciones metodológicas o contextuales modifican su interpretación?

MÉTODOS

Método PRISMA y criterios analíticos


Se desarrolló una revisión sistemática orientada a sintetizar evidencia académica pertinente para el tema del manuscrito. La unidad de análisis fue el estudio o referencia académica con fuente trazable, metodología identificable y resultados recuperables. El corpus académico consolidado de trabajo estuvo compuesto por 135 registros previamente reunidos en las matrices de evidencia. Sobre ese conjunto se aplicó una selección temática y documental para establecer el corpus final. El procedimiento se organizó conforme a la lógica de identificación, cribado, elegibilidad e inclusión de PRISMA, adaptada al carácter consolidado de las fuentes suministradas. La estructura de reporte se apoyó además en la declaración PRISMA 2020 (26).

Los criterios de inclusión exigieron relación directa con analítica del aprendizaje para predecir rendimiento y riesgo de abandono en educación superior, correspondencia con educación superior o con instrumentos aplicables a ese nivel, descripción suficiente del método y disponibilidad de resultados interpretables. Se excluyeron 130 registros por menor pertinencia respecto de la pregunta específica, por tratar poblaciones o desenlaces periféricos, o por no aportar evidencia metodológica suficiente para la síntesis focal. El corpus final quedó constituido por 5 estudios. La selección se efectuó sobre la información documentada en las matrices y se evitó atribuir a una base bibliográfica particular conteos que no estuvieran respaldados por los archivos.

La extracción de información se estructuró mediante una matriz con autores, año, título, fuente, DOI o enlace trazable, procedencia, tipo de estudio, muestra o corpus, metodología resumida, resultados principales, nivel de evidencia y pertinencia. Esta organización permitió comparar trabajos con diseños heterogéneos sin reducirlos a una única métrica. La síntesis combinó caracterización descriptiva del corpus y análisis temático de los resultados, prestando atención a convergencias, contradicciones, condiciones de implementación y límites de generalización.

La evaluación de la evidencia se centró en la suficiencia de la información recuperada para responder la pregunta de revisión. Se consideraron de forma conjunta la claridad del diseño, la explicitación de la muestra o corpus, la correspondencia entre método y resultados y la trazabilidad de la fuente. No se realizó metaanálisis cuando la heterogeneidad de desenlaces, instrumentos, poblaciones o métricas impedía una combinación cuantitativa responsable. En esos casos se priorizó una síntesis comparativa que preserve las diferencias entre estudios y evita transformar resultados no equivalentes en un único estimador.

Figura 2. Flujo de selección de estudios según la lógica PRISMA



Fuente: elaboración propia a partir de la matriz de evidencia de la revisión.

Nota. El flujo representa 135 registros académicos normalizados, sin duplicados en el corpus consolidado; 130 registros no cumplieron el umbral de pertinencia temática y 5 estudios integraron la síntesis final.

Para fortalecer la transparencia, los resultados se organizaron en tablas de caracterización y síntesis, mientras que las figuras representan el flujo de selección y la distribución temporal del corpus. Cada tabla fue construida a partir de los campos de la matriz suministrada. Las interpretaciones posteriores se elaboraron sobre patrones observables en el conjunto y no sobre supuestos añadidos. Este criterio es especialmente importante en revisiones educativas, donde la variación entre disciplinas, tecnologías, instrumentos y contextos institucionales puede modificar sustancialmente la magnitud y el significado de los hallazgos.

El flujo documenta la depuración y selección de la evidencia. Los 135 registros del corpus consolidado se encontraban normalizados por DOI o título, por lo que no se identificaron duplicados en esta etapa. El cribado temático excluyó 130 registros por insuficiente correspondencia con la pregunta específica de la revisión, mientras que 5 estudios conservaron evidencia metodológica y resultados suficientemente recuperables para integrar la síntesis. La secuencia permite distinguir la identificación documental del juicio de elegibilidad y evita interpretar la reducción del corpus como una pérdida arbitraria de información.

RESULTADOS

El corpus final reunió 5 estudios publicados durante 2022–2026. La distribución temporal muestra un campo de investigación activo y heterogéneo, con trabajos que responden a distintas fases de maduración del problema. Algunos se concentran en demostrar viabilidad o asociación, mientras otros avanzan hacia validación, comparación de estrategias o análisis de condiciones de implementación. Esta amplitud temporal permite observar no solo resultados favorables, sino también desplazamientos en la forma de conceptualizar la calidad de la evaluación y en el tipo de evidencia que se considera necesaria para respaldar decisiones educativas.

La caracterización metodológica confirma que analítica del aprendizaje para predecir rendimiento y riesgo de abandono en educación superior no constituye un objeto homogéneo. En el conjunto aparecen diseños con finalidades distintas y niveles variables de control sobre las condiciones de estudio. Esta diversidad amplía el alcance de la revisión, aunque también obliga a interpretar los hallazgos de acuerdo con la función de cada diseño. Los trabajos de intervención informan sobre cambios observados bajo condiciones definidas; los estudios instrumentales aportan evidencia sobre medición; los análisis observacionales describen asociaciones; y las revisiones previas permiten reconocer tendencias del campo sin sustituir la evaluación de los estudios primarios.

Las muestras y corpus descritos en los estudios presentan una variabilidad considerable. Esa variación es relevante porque la transferibilidad de los resultados depende del tamaño, composición y contexto de los participantes, así como de la disciplina académica y del entorno tecnológico. En conjunto, la evidencia sugiere que los resultados más interpretables son aquellos que explicitan la población, la tarea evaluativa y el mecanismo mediante el cual la intervención o instrumento debería producir el efecto esperado. Cuando alguno de esos elementos permanece poco definido, la utilidad del hallazgo para decisiones institucionales disminuye.

La síntesis de resultados revela un patrón central vinculado con predicción educativa: los efectos o propiedades favorables no aparecen como atributos automáticos de la tecnología o del instrumento, sino como resultados condicionados por diseño, implementación, calidad de datos y alineación pedagógica. Los estudios convergen en la importancia de articular la herramienta con objetivos de aprendizaje claros, criterios de evaluación comprensibles y mecanismos de seguimiento. Las divergencias se concentran en la magnitud de los efectos, la estabilidad entre contextos y la capacidad de sostener resultados cuando cambian las condiciones institucionales. Este patrón coincide con investigaciones sobre sistemas de alerta temprana, analítica predictiva y predicción del rendimiento académico^{11–17, 28–29}.


La tabla evidencia la diversidad metodológica del corpus y permite observar que los estudios no ofrecen el mismo tipo de inferencia. La presencia de diseños con objetivos distintos exige interpretar cada resultado según la pregunta que el estudio puede responder. Esta diferenciación evita comparar directamente indicadores que cumplen funciones diferentes y ayuda a identificar dónde existe convergencia real. También muestra que la solidez de una conclusión depende de la combinación entre claridad metodológica, descripción de la muestra y suficiencia de la evidencia recuperada.

Tabla 1. Caracterización metodológica del corpus incluido

Año	Diseño/metodología	Muestra o corpus	Evidencia
2024	Estudio predictivo de machine learning	Datos de una universidad finlandesa; expedientes, demografía y Moodle	Alta
2022	Modelado predictivo ensemble	Datos universitarios 2016–2020 de Constantine the Philosopher University	Alta
2026	Learning analytics predictivo	99,104 registros de actividad de 154 estudiantes	Alta
2022	Modelado multinivel y machine learning	Datos administrativos de una universidad italiana	Alta
2025	Estudio metodológico con simulación y datos reales	conjunto de datos real	Alta

Nota. Datos extraídos de la matriz de evidencia suministrada para esta revisión.

Figura 3. Distribución temporal de los estudios incluidos



Nota. Frecuencias calculadas a partir del año de publicación registrado en la matriz de evidencia.

La distribución temporal permite situar la intensidad reciente de la producción científica y reconocer si el campo se encuentra en expansión, consolidación o transición metodológica. Más que interpretar el número de publicaciones como una medida de calidad, la figura sirve para contextualizar los cambios en preguntas, tecnologías e instrumentos observados en el corpus. La lectura conjunta con la caracterización metodológica permite identificar si los trabajos más recientes amplían la evidencia mediante diseños más robustos o si continúan predominando aproximaciones exploratorias.

Rendimiento predictivo y transferibilidad

Otro patrón transversal es la relevancia de la calidad de la evidencia. Los estudios con procedimientos explícitos permiten distinguir mejor entre mejora real, percepción favorable y simple facilidad de uso. En cambio, cuando el resultado se apoya principalmente en autoinforme o en indicadores de corto plazo, la interpretación requiere mayor cautela. La revisión muestra que la utilidad práctica de una estrategia no depende únicamente de que produzca una diferencia estadística o una valoración positiva, sino de que la medición sea coherente con el constructo y de que la intervención pueda integrarse de manera sostenible en procesos educativos reales.

En el subconjunto de evidencia correspondiente a este eje se observaron resultados que, considerados conjuntamente, pueden resumirse de la siguiente manera: Los datos LMS resultaron potentes para predecir abandono; créditos, cursos fallidos y actividad Moodle fueron predictores importantes. El ensemble superó a modelos base en accuracy y AUC, permitiendo identificar estudiantes en riesgo para intervención temprana. Los modelos identificaron estudiantes en riesgo y permitieron alertas tempranas y apoyo adaptativo. La lectura comparada indica que estos hallazgos no deben interpretarse como equivalentes, porque proceden de diseños y métricas diferentes.

Sin embargo, su convergencia temática permite identificar condiciones recurrentes y formular una interpretación de conjunto centrada en la relación entre calidad del diseño, respuesta de los estudiantes y utilidad de la información producida para orientar decisiones educativas.

En el subconjunto de evidencia correspondiente a este eje se observaron resultados que, considerados conjuntamente, pueden resumirse de la siguiente manera: Demostró viabilidad de un sistema de alerta temprana para identificar riesgo de abandono. La medida identificó correctamente características responsables del sesgo en simulaciones y halló conjuntos consistentes de variables en datos reales. La lectura comparada indica que estos hallazgos no deben interpretarse como equivalentes, porque proceden de diseños y métricas diferentes. Sin embargo, su convergencia temática permite identificar condiciones recurrentes y formular una interpretación de conjunto centrada en la relación entre calidad del diseño, respuesta de los estudiantes y utilidad de la información producida para orientar decisiones educativas.

La síntesis muestra que la evidencia favorable se distribuye entre distintos tipos de resultados y que la pertinencia de cada estudio depende de su proximidad con el constructo central. Los hallazgos no se interpretan como intercambiables: algunos describen rendimiento, otras propiedades de medición, experiencia estudiantil, accesibilidad o desempeño de modelos. La comparación permite reconocer convergencias sin perder la especificidad de cada resultado y constituye la base para la discusión de mecanismos y condiciones de implementación.

Tabla 2. Síntesis de hallazgos relevantes

Estudio	Hallazgo recuperado	Pertinencia
Predicting student dropouts with machine learning: An empirical study in Finnish higher ed	Los datos LMS resultaron potentes para predecir abandono; créditos, cursos fallidos y actividad Moodle fueron predictores importantes.	Incluido por pertinencia directa con la
Predicting student's dropout in university classes using two-layer ensemble machine learni	El ensemble superó a modelos base en accuracy y AUC, permitiendo identificar estudiantes en riesgo para intervención temprana.	Incluido por pertinencia directa con la
Using AI to forecast student dropout risk in technical education using a learning analytic	Los modelos identificaron estudiantes en riesgo y permitieron alertas tempranas y apoyo adaptativo.	Incluido por pertinencia directa con la
Early-predicting dropout of university students: an application of innovative multilevel m	Demostró viabilidad de un sistema de alerta temprana para identificar riesgo de abandono.	Incluido por pertinencia directa con la
Identifying Features Contributing to Differential Prediction Bias of Automated Scoring Sys	La medida identificó correctamente características responsables del sesgo en simulaciones y halló conjuntos consistentes de variables en datos reales.	Incluido por pertinencia directa con la

Nota. Síntesis textual basada exclusivamente en los resultados registrados en la matriz.

DISCUSIÓN

La síntesis permite sostener que el problema de analítica del aprendizaje para predecir rendimiento y riesgo de abandono en educación superior debe interpretarse desde una lógica de predicción educativa y no desde una oposición simplificada entre tecnología eficaz e ineficaz. Los estudios revisados muestran que el desempeño de una estrategia depende de la interacción entre propósito evaluativo, características de los estudiantes, diseño de la tarea, calidad de la medición y capacidad institucional para utilizar la información generada. Esta conclusión desplaza la atención desde la herramienta aislada hacia el sistema de evaluación en el que se inserta.

Una consecuencia importante es que la innovación tecnológica no elimina los problemas clásicos de validez, fiabilidad, equidad y utilidad. Por el contrario, puede hacerlos más visibles al ampliar la escala y velocidad de las decisiones. La evidencia revisada sugiere que las mejores implementaciones son aquellas que hacen explícitos los criterios, preservan oportunidades de retroalimentación y mantienen mecanismos de revisión humana cuando las consecuencias de una decisión son relevantes. En este sentido, la digitalización debe entenderse como una transformación del proceso evaluativo y no como una sustitución automática del juicio académico. La literatura sobre privacidad, ética y justicia en analítica del aprendizaje refuerza la necesidad de transparencia, control institucional y protección de los estudiantes (18–23).

La heterogeneidad observada también explica por qué no resulta adecuado reducir el campo a un único tamaño de efecto. Las investigaciones difieren en constructos, duración, instrumentos, disciplinas, muestras y métricas. Esa variación no constituye únicamente una limitación; también

aporta información sobre los contextos en los que una estrategia funciona y sobre las condiciones que deben ser consideradas antes de transferirla. La síntesis comparativa permite reconocer patrones de consistencia sin borrar diferencias que son esenciales para la toma de decisiones educativas.

Desde el punto de vista metodológico, el corpus evidencia una transición desde estudios centrados en adopción y percepción hacia diseños que buscan demostrar calidad de medición, impacto en resultados y sostenibilidad de la intervención. Sin embargo, persisten vacíos relacionados con comparaciones longitudinales, replicación entre instituciones, análisis de subgrupos y documentación de efectos no previstos. La agenda futura debería priorizar diseños que conecten resultados de aprendizaje con procesos de implementación y que informen no solo si una intervención funciona, sino para quién, bajo qué condiciones y con qué costos pedagógicos u organizacionales. Esta evolución también se observa en revisiones y marcos recientes que sitúan la analítica del aprendizaje dentro de estrategias institucionales, diseños pedagógicos y aplicaciones de inteligencia artificial en educación superior^{24–25, 27–28}.

La principal contribución de esta revisión consiste en organizar la evidencia de forma que los resultados puedan utilizarse para decisiones académicas sin sobreextender sus alcances. La convergencia entre estudios ofrece argumentos para adoptar prácticas prometedoras, pero la diversidad metodológica exige preservar una lógica de evaluación continua. Las instituciones deberían tratar cada implementación como una intervención susceptible de seguimiento, con indicadores definidos antes de su despliegue y mecanismos para revisar resultados, sesgos, experiencia estudiantil y coherencia con los objetivos curriculares.

Vaarma y Lilofre² ofrece un punto de contraste útil para esta interpretación porque su estudio documenta los datos LMS resultaron potentes para predecir abandono; créditos, cursos fallidos y actividad Moodle fueron predictores importantes. Este hallazgo adquiere mayor significado cuando se compara con el resto del corpus: no actúa como evidencia autosuficiente, sino como una observación que ayuda a precisar mecanismos, límites y condiciones de aplicación. La lectura sistemática permite así evitar dos extremos frecuentes, la generalización excesiva a partir de un solo estudio y la pérdida de información contextual cuando se sintetizan resultados heterogéneos.

Niyogisubizo et al.²⁰ ofrece un punto de contraste útil para esta interpretación porque su estudio documenta el ensemble superó a modelos base en accuracy y AUC, permitiendo identificar estudiantes en riesgo para intervención temprana. Este hallazgo adquiere mayor significado cuando se compara con el resto del corpus: no actúa como evidencia autosuficiente, sino como una observación que ayuda a precisar mecanismos, límites y condiciones de aplicación. La lectura sistemática permite así evitar dos extremos frecuentes, la generalización excesiva a partir de un solo estudio y la pérdida de información contextual cuando se sintetizan resultados heterogéneos.

Ovtšarenko³⁰ ofrece un punto de contraste útil para esta interpretación porque su estudio documenta los modelos identificaron estudiantes en riesgo y permitieron alertas tempranas y apoyo adaptativo. Este hallazgo adquiere mayor significado cuando se compara con el resto del corpus: no actúa como evidencia autosuficiente, sino como una observación que ayuda a precisar mecanismos, límites y condiciones de aplicación. La lectura sistemática permite así evitar dos extremos frecuentes, la generalización excesiva a partir de un solo estudio y la pérdida de información contextual cuando se sintetizan resultados heterogéneos.

Cannistrà et al.⁴⁰ ofrece un punto de contraste útil para esta interpretación porque su estudio documenta demostró viabilidad de un sistema de alerta temprana para identificar riesgo de abandono. Este hallazgo adquiere mayor significado cuando se compara con el resto del corpus: no actúa como evidencia autosuficiente, sino como una observación que ayuda a precisar mecanismos, límites y condiciones de aplicación. La lectura sistemática permite así evitar dos extremos frecuentes, la generalización excesiva a partir de un solo estudio y la pérdida de información contextual cuando se sintetizan resultados heterogéneos.

Choi y Johnson⁵⁰ ofrece un punto de contraste útil para esta interpretación porque su estudio documenta la medida identificó correctamente características responsables del sesgo en simulaciones y halló conjuntos consistentes de variables en datos reales. Este hallazgo adquiere mayor significado cuando se compara con el resto del corpus: no actúa como evidencia autosuficiente, sino como una observación que ayuda a precisar mecanismos, límites y condiciones de aplicación. La lectura sistemática permite así evitar dos extremos frecuentes, la generalización excesiva a partir de un solo estudio y la pérdida de información contextual cuando se sintetizan resultados heterogéneos.

Riesgos de decisión y uso institucional

Las implicaciones prácticas derivadas de la revisión deben traducirse en decisiones graduales. Para analítica del aprendizaje para predecir rendimiento y riesgo de abandono en educación superior, una implementación responsable requiere definir previamente el constructo que se desea medir, establecer indicadores de éxito, identificar grupos potencialmente afectados y prever mecanismos de revisión. La evidencia disponible favorece estrategias que integran la innovación con acompañamiento docente y evaluación continua de resultados.

En el plano institucional, la adopción debería acompañarse de protocolos de gobernanza de datos, criterios de transparencia y mecanismos de comunicación con estudiantes y docentes. Estas condiciones aumentan la interpretabilidad de los resultados y reducen el riesgo de utilizar indicadores fuera del contexto para el que fueron diseñados. La evaluación de una herramienta debe considerar tanto desempeño técnico como consecuencias pedagógicas y distributivas. La evidencia disponible recomienda incorporar consentimiento informado, privacidad, transparencia y participación de los actores institucionales en la gobernanza de estos sistemas¹⁸⁻²⁴.

Para la investigación, el siguiente paso consiste en conectar mejor los estudios de eficacia con los de implementación. Resulta necesario saber no solo si una estrategia produce cambios, sino qué componentes explican esos cambios, qué recursos demanda y cómo se comporta en poblaciones diversas. Esa orientación permitiría acumular evidencia de forma más coherente y reducir la fragmentación que actualmente caracteriza parte de la literatura.

Prioridades de investigación

La principal limitación del corpus es su heterogeneidad. Las diferencias entre diseños, instrumentos, poblaciones y desenlaces restringen la posibilidad de producir un estimador común y obligan a interpretar los patrones desde una lógica comparativa. Esta limitación no invalida la síntesis, pero sí condiciona el alcance de las conclusiones y refuerza la necesidad de replicaciones con protocolos comparables.

También se observa una concentración de estudios en determinados contextos y tecnologías, lo que reduce la certeza sobre la transferibilidad a instituciones con infraestructura, perfiles estudiantiles o culturas de evaluación diferentes. Las investigaciones futuras deberían documentar con mayor precisión condiciones de implementación, características de los participantes y decisiones adoptadas durante el despliegue de las herramientas.

Finalmente, la revisión se apoya en el corpus consolidado documentado en las matrices suministradas. Las conclusiones representan fielmente ese conjunto y no se extienden a registros que no forman parte de la evidencia disponible. Esta delimitación preserva la trazabilidad y permite que futuras actualizaciones incorporen nuevos estudios sin alterar retrospectivamente la base analítica utilizada en el presente manuscrito.

CONCLUSIONES

La revisión sistemática muestra que analítica del aprendizaje para predecir rendimiento y riesgo de abandono en educación superior constituye un campo con evidencia suficiente para identificar patrones, pero todavía heterogéneo en diseños, poblaciones y métricas. El resultado central es que la calidad de las decisiones depende menos de la presencia aislada de una tecnología o instrumento que de su integración con objetivos de aprendizaje, criterios explícitos y procedimientos de seguimiento. La perspectiva de predicción educativa permite comprender por qué intervenciones similares pueden producir resultados diferentes y por qué la evaluación de efectividad debe considerar simultáneamente resultados, condiciones y calidad de la medición.

En términos aplicados, las instituciones de educación superior deberían adoptar una lógica gradual de implementación, con pruebas controladas, documentación de resultados y revisión periódica de efectos sobre distintos grupos de estudiantes. La evidencia respalda el uso de estrategias digitales cuando existe alineación pedagógica y cuando la información generada se utiliza para mejorar la enseñanza y el aprendizaje. También muestra la necesidad de evitar decisiones automáticas basadas en indicadores únicos, especialmente cuando las consecuencias académicas son relevantes o cuando existen diferencias de acceso, experiencia tecnológica o necesidades de apoyo.

La agenda de investigación debe avanzar hacia estudios longitudinales, comparaciones multicéntricas y diseños que documenten con mayor precisión mecanismos y efectos diferenciales. También se requiere mejorar la comparabilidad de indicadores y la transparencia en la descripción

de instrumentos, algoritmos y procedimientos de intervención. Estas prioridades permitirán transformar un campo caracterizado por rápida innovación en una base de evidencia más acumulativa, replicable y útil para políticas universitarias. La revisión aporta una estructura para ese avance al separar hallazgos consistentes, condiciones de implementación y vacíos que todavía requieren investigación. Revisiones del campo señalan igualmente la necesidad de mejorar la generalización, la comparabilidad de modelos y la evaluación de intervenciones basadas en analítica predictiva^{6–10, 16, 24–25}.

Referencias

1. Vaarma M, Li H. Predicting student dropouts with machine learning: An empirical study in Finnish higher education. *Technology in Society*. 2024;76:102474. <https://doi.org/10.1016/j.techsoc.2024.102474>
2. Niyogisubizo J, Liao L, Nziyumva E, Murwanashyaka E, Nshimyumukiza PC. Predicting student's dropout in university classes using two-layer ensemble machine learning approach: A novel stacked generalization. *Computers and Education: Artificial Intelligence*. 2022;3:100066. <https://doi.org/10.1016/j.caeai.2022.100066>
3. Ovtšarenko O. Using AI to forecast student dropout risk in technical education using a learning analytics approach. *Scientific Reports*. 2026;16:14616. <https://doi.org/10.1038/s41598-026-44919-1>
4. Cannistrà M, Masci C, Ieva F, Agasisti T, Paganoni AM. Early-predicting dropout of university students: an application of innovative multilevel machine learning and statistical techniques. *Studies in Higher Education*. 2022;47(9):1935–1956. <https://doi.org/10.1080/03075079.2021.2018415>
5. Choi I, Johnson MS. Identifying Features Contributing to Differential Prediction Bias of Automated Scoring Systems. *Journal of Educational Measurement*. 2025;62(4):838–861. <https://doi.org/10.1111/jedm.70015>
6. de Oliveira CF, Sobral SR, Ferreira MJ, Moreira F. How Does Learning Analytics Contribute to Prevent Students' Dropout in Higher Education: A Systematic Literature Review. *Big Data and Cognitive Computing*. 2021;5(4):64. <https://doi.org/10.3390/bdcc5040064>
7. Larrabee Sønderlund A, Hughes E, Smith J. The efficacy of learning analytics interventions in higher education: A systematic review. *British Journal of Educational Technology*. 2019;50:2594–2618. <https://doi.org/10.1111/bjet.12720>
8. Ifenthaler D, Yau JYK. Utilising learning analytics to support study success in higher education: a systematic review. *Educational Technology Research and Development*. 2020;68:1961–1990. <https://doi.org/10.1007/s11423-020-09788-z>
9. Viberg O, Hatakka M, Bälter O, Mavroudi A. The current landscape of learning analytics in higher education. *Computers in Human Behavior*. 2018;89:98–110. <https://doi.org/10.1016/j.chb.2018.07.027>
10. Gašević D, Dawson S, Rogers T, Gašević D. Learning analytics should not promote one size fits all: The effects of instructional conditions in predicting academic success. *The Internet and Higher Education*. 2016;28:68–84. <https://doi.org/10.1016/j.iheduc.2015.10.002>
11. Herodotou C, Rienties B, Boroowa A, Zdrahal Z, Hlosta M. A large-scale implementation of predictive learning analytics in higher education: the teachers' role and perspective. *Educational Technology Research and Development*. 2019;67:1273–1306. <https://doi.org/10.1007/s11423-019-09685-0>
12. Plak S, Cornelisz I, Meeter M, van Klaveren C. Early warning systems for more effective student counselling in higher education: Evidence from a Dutch field experiment. *Higher Education Quarterly*. 2022;76(1):131–152. <https://doi.org/10.1111/hequ.12298>
13. Karalar H, Kapucu C, Gürüler H. Predicting students at risk of academic failure using ensemble model during pandemic in a distance learning system. *International Journal of Educational Technology in Higher Education*. 2021;18:63. <https://doi.org/10.1186/s41239-021-00300-y>
14. Hu YH, Lo CL, Shih SP. Developing early warning systems to predict students' online learning performance. *Computers in Human Behavior*. 2014;36:469–478. <https://doi.org/10.1016/j.chb.2014.04.002>
15. Riestra-González M, del Puerto Paule-Ruiz M, Ortín F. Massive LMS log data analysis for the early prediction of course-agnostic student performance. *Computers & Education*. 2021;163:104108. <https://doi.org/10.1016/j.compedu.2020.104108>
16. Sghir N, Adadi A, Lahmer M. Recent advances in Predictive Learning Analytics: A decade systematic review (2012–2022). *Education and Information Technologies*. 2023;28(7):8299–8333. <https://doi.org/10.1007/s10639-022-11536-0>
17. Tamada MM, Giusti R, Netto JFM. Predicting Students at Risk of Dropout in Technical Course Using LMS Logs. *Electronics*. 2022;11(3):468. <https://doi.org/10.3390/electronics11030468>
18. Pardo A, Siemens G. Ethical and privacy principles for learning analytics. *British Journal of Educational Technology*. 2014;45(3):438–450. <https://doi.org/10.1111/bjet.12152>
19. Ifenthaler D, Schumacher C. Student perceptions of privacy principles for learning analytics. *Educational Technology Research and Development*. 2016;64(5):923–938. <https://doi.org/10.1007/s11423-016-9477-y>
20. Jones KML. Learning analytics and higher education: a proposed model for establishing informed consent mechanisms to promote student privacy and autonomy. *International Journal of Educational Technology in Higher Education*. 2019;16:24. <https://doi.org/10.1186/s41239-019-0155-0>
21. Jones KML, Asher A, Goben A, Perry MR, Salo D, Briney KA, et al. 'We're being tracked at all times': Student perspectives of their privacy in relation to learning analytics in higher education. *Journal of the Association for Information Science and Technology*. 2020;71(9):1044–1059. <https://doi.org/10.1002/asi.24358>
22. Currier C. Unresolved Privacy and Ethics Issues Related to Learning Analytics in Higher Education and Academic Librarianship. *Emerging Library & Information Perspectives*. 2021;4(1):117–142. <https://doi.org/10.5206/elp.v4i1.13463>
23. Johnson JA. Ethics and Justice in Learning Analytics. *New Directions for Higher Education*. 2017;2017(179):77–87. <https://doi.org/10.1002/he.20245>
24. Gašević D, Tsai YS, Drachsler H. Learning analytics in higher education – Stakeholders, strategy and scale. *The Internet and Higher Education*. 2022;52:100833. <https://doi.org/10.1016/j.iheduc.2021.100833>
25. Blumenstein M. Synergies of Learning Analytics and Learning Design: A Systematic Review of Student Outcomes. *Journal of Learning Analytics*. 2020;7(3):13–32. <https://doi.org/10.18608/jla.2020.73.3>

26. Page MJ, McKenzie JE, Bossuyt PM, Boutron I, Hoffmann TC, Mulrow CD, et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*. 2021;372:n71. <https://doi.org/10.1136/bmj.n71>
27. Zawacki-Richter O, Marín VI, Bond M, Gouverneur F. Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*. 2019;16:39. <https://doi.org/10.1186/s41239-019-0171-0>
28. Oliva-Cordova LM, Garcia-Cabot A, Amado-Salvatierra HR. Learning Analytics to Support Teaching Skills: A Systematic Literature Review. *IEEE Access*. 2021;9:58351–58363. <https://doi.org/10.1109/ACCESS.2021.3070294>.
29. Nabil A, Seyam M, Abou Elfetouh A. Prediction of Students' Academic Performance Based on Courses' Grades Using Deep Neural Networks. *IEEE Access*. 2021;9:140731–140746. <https://doi.org/10.1109/ACCESS.2021.3119596>.

Financiación

No aplica.

Conflictos de interés

No existen.

Contribución de autoría

Conceptualización: Freddy Leonardo Garaicoa Fuentes

Curación de datos: Freddy Leonardo Garaicoa Fuentes

Análisis formal: Freddy Leonardo Garaicoa Fuentes

Investigación: Freddy Leonardo Garaicoa Fuentes

Metodología: Freddy Leonardo Garaicoa Fuentes

Supervisión: Freddy Leonardo Garaicoa Fuentes

Validación: Freddy Leonardo Garaicoa Fuentes

Visualización: Freddy Leonardo Garaicoa Fuentes

Redacción – borrador original: Freddy Leonardo Garaicoa Fuentes

Redacción – revisión y edición: Freddy Leonardo Garaicoa Fuentes