

CAPÍTULO 7

GESTIÓN ACADÉMICA BASADA EN DATOS E INTELIGENCIA ARTIFICIAL

José Wilson Gómez Cumpa

Universidad Nacional Pedro Ruiz Gallo, Lambayeque, Perú

<https://orcid.org/0000-0001-7071-6248>

María Margarita Fanning Balarezo

Universidad Nacional Pedro Ruiz Gallo, Lambayeque, Perú

<https://orcid.org/0000-0002-2666-4935>

7.1 INTRODUCCIÓN

La gestión de las instituciones de educación superior (IES) ha experimentado, en la primera mitad del siglo XXI, una transformación que va mucho más allá de la digitalización de procesos administrativos. Asistimos a un cambio de paradigma en el que la toma de decisiones basada en evidencia —apoyada por la analítica de datos y, de manera creciente, por la inteligencia artificial (IA)— se convierte en el eje articulador de la gobernanza universitaria. Este tránsito supone pasar de la gestión reactiva, que responde a crisis ya consumadas, a una gestión proactiva, capaz de anticipar riesgos, optimizar recursos y orientar intervenciones precisas sobre el estudiantado.

La literatura especializada de 2023 a 2026 coincide en describir la gestión académica basada en datos (data-driven academic management, DDAM) como una capacidad institucional para convertir datos

heterogéneos —provenientes de sistemas de información estudiantil (SIS), plataformas de gestión del aprendizaje (LMS), sistemas de recursos humanos y registros externos— en conocimiento accionable para el liderazgo directivo, la planeación estratégica, la rendición de cuentas y las intervenciones de éxito estudiantil (Gaftandzhieva et al., 2023). Los tableros de control (dashboards) y los enfoques de inteligencia de negocios (business intelligence) se consolidan como la interfaz operativa, mientras que la IA añade capacidades de análisis predictivo, modelado de escenarios y automatización de procesos administrativos (Ogwuche, 2025).

En América Latina y el Caribe (ALC), la evidencia más relevante se concentra en tres desafíos interconectados: la retención estudiantil (con tasas de deserción universitaria que la UNESCO estima entre el 30 % y el 50 % en varios países de la región), los sistemas de alerta temprana (SAT) y los riesgos de que la instrumentalización excesiva de métricas derive en una tecnocratización de la gestión educativa. Este capítulo aborda cada uno de estos ejes, articulando la literatura internacional con experiencias regionales y señalando las condiciones institucionales necesarias para que la adopción de estas tecnologías sea pertinente, equitativa y éticamente responsable.

El objetivo del capítulo es analizar cómo la gestión académica basada en datos e IA puede fortalecer la planeación, la retención y el éxito estudiantil en instituciones de educación superior de América Latina y el Caribe, sin perder de vista sus límites éticos, pedagógicos e institucionales. Su relevancia radica en proponer una ruta de adopción responsable que combine capacidad técnica, gobernanza del dato, participación institucional y centralidad del juicio humano.

7.2 MARCO TEÓRICO Y FUNDAMENTACIÓN CONCEPTUAL

El análisis que sustenta este capítulo se fundamenta en tres corrientes teóricas convergentes. La primera es la teoría de la cognición distribuida y sistemas sociotécnicos, que concibe la gestión universitaria no como un proceso centralizado, sino como una red de interacciones entre actores humanos, artefactos tecnológicos y flujos de información (Norman, 1993; Orlikowski, 2007). La segunda es el marco de la analítica educativa y learning analytics, que define la medición, recolección, análisis y reporte de datos sobre aprendientes y sus contextos como un ciclo continuo orientado a comprender y optimizar el aprendizaje (Siemens & Long, 2011; Gaftandzhieva et al., 2023). La tercera corriente es la gobernanza algorítmica y ética de datos, que problematiza la delegación de decisiones

institucionales en sistemas opacos y exige principios de transparencia, equidad y rendición de cuentas (Floridi et al., 2018; UNESCO, 2021).

Sobre esta base se articulan dos distinciones operativas. La primera es la jerarquía DIKW (Datos, Información, Conocimiento, Sabiduría), que permite diferenciar la acumulación técnica de datos de la capacidad institucional para transformarlos en decisiones pedagógicamente legítimas. La segunda es la tipología analítica (descriptiva, predictiva, prescriptiva), que establece niveles de madurez institucional y define los límites de lo que la IA puede anticipar versus lo que requiere juicio humano y contexto situado. Estas bases teóricas permiten superar el determinismo tecnológico y situar la IA como infraestructura de apoyo a la misión académica, no como sustituto de la deliberación universitaria.

7.3 METODOLOGÍA

Dado el carácter analítico y propositivo del capítulo, se adoptó una metodología de revisión narrativa crítica y análisis documental de evidencia empírica reciente (2019–2026). Se triangularon reportes multilaterales e institucionales, literatura especializada en analítica educativa y estudios de caso en América Latina y el Caribe (Colombia, Perú, México, Chile y Ecuador). Este procedimiento permitió construir un marco operativo de gestión académica basada en datos, identificando variables predictivas de deserción, arquitectura de sistemas de alerta temprana y condiciones institucionales para mitigar riesgos de tecnocratización, sesgo algorítmico y dependencia tecnológica.

Los criterios de inclusión priorizaron fuentes académicas, informes institucionales y estudios aplicados que abordaran educación superior, analítica de datos, inteligencia artificial, retención estudiantil, sistemas de alerta temprana o gobernanza de datos. Se excluyeron textos centrados exclusivamente en educación básica, usos aislados de herramientas digitales o reflexiones sin conexión directa con la gestión académica institucional. Al tratarse de revisión documental sin intervención con seres humanos, animales o plantas, no se requirió aprobación de comité de ética; no obstante, el análisis se orientó por principios de transparencia, trazabilidad de fuentes y uso responsable de la evidencia.

7.4 IA y toma de decisiones institucionales

7.4.1 Del dato al conocimiento accionable: la cadena de valor informacional

El valor estratégico de la IA en la gestión universitaria no reside en la tecnología per se, sino en su capacidad para cerrar la brecha entre la acumulación masiva de datos —que caracteriza a las IES

contemporáneas— y la generación de conocimiento accionable para directivos, académicos y personal de apoyo. Esta cadena de valor informacional puede describirse como una jerarquía ascendente que transita de los datos brutos (registros transaccionales de sistemas dispersos) a la información (indicadores procesados y contextualizados), al conocimiento (patrones interpretados en relación con los objetivos institucionales) y, finalmente, a la sabiduría aplicada (decisiones estratégicas con base en evidencia y juicio humano).

Desde esta perspectiva, los Sistemas de Soporte a la Decisión impulsados por IA no solo automatizan tareas; permiten a la institución percibir, razonar y actuar de manera anticipatoria. Esta capacidad exige, sin embargo, condiciones organizacionales previas: integración de sistemas de información, calidad y gobierno del dato, y alfabetización en analítica por parte de directivos y equipos técnicos (Asfaw et al., 2023; Márquez et al., 2023).

7.4.2 Arquitecturas de información para la gestión académica

La literatura identifica dos niveles complementarios de arquitectura informacional en la gestión académica universitaria. El primer nivel es el de la inteligencia de negocios (BI, por sus siglas en inglés), que consolida datos históricos de múltiples fuentes en repositorios centralizados (data warehouses) y los pone a disposición de directivos mediante tableros de control con indicadores clave de desempeño (KPIs). El segundo nivel es el de la analítica avanzada y la IA, que incorpora modelos de aprendizaje automático (machine learning), procesamiento de lenguaje natural y modelado predictivo para generar alertas, proyecciones y recomendaciones en tiempo cuasi real (Sharma & Joshi, 2022; Ogwuche, 2025).

Un elemento crítico señalado de manera consistente en la literatura es que la mera disponibilidad de datos no garantiza mejores decisiones. La integración entre sistemas —SIS, LMS, ERP, plataformas de bienestar estudiantil— es condición sine qua non para que los modelos de IA dispongan de insumos suficientes y representativos. En contextos de ALC, la fragmentación de sistemas de información y la ausencia de políticas de gobierno del dato representan las principales barreras para escalar estas capacidades más allá de proyectos piloto (Asfaw et al., 2023). La Tabla 7.1 sintetiza las diferencias entre ambos modelos de gestión.

Tabla 7.1

Características comparativas entre la gestión tradicional y la gestión basada en datos e IA en IES

Dimensión	Gestión tradicional (reactiva)	Gestión basada en datos e IA (proactiva)
Fuente de información	Informes anuales, encuestas, intuición directiva	Dashboards en tiempo real, modelos predictivos, KPIs integrados
Ciclo de decisión	Semestral o anual; responde a crisis ya ocurridas	Continuo; anticipa tendencias y detecta señales tempranas
Cobertura de datos	Silos departamentales no integrados	Integración de SIS, LMS, ERP y fuentes externas
Rol del liderazgo	Gestor de operaciones y resolución de problemas	Estratega que interpreta analítica y orienta acción
Equidad y transparencia	Decisiones poco auditables, subjetividad elevada	Trazabilidad algorítmica; requiere supervisión humana activa

Nota. Elaboración propia con base en Gaftandzhieva et al. (2023), Ogwuche (2025) y Asfaw et al. (2023).

7.4.3 Analítica descriptiva, predictiva y prescriptiva

La gestión académica basada en datos opera en tres horizontes analíticos que corresponden a distintos grados de madurez institucional. La analítica descriptiva responde a la pregunta de qué ocurrió: reportes de rendimiento, tasas de aprobación, tasas de retención por cohorte, métricas de investigación y de gestión de recursos. La analítica predictiva responde a qué podría ocurrir: modelos que calculan probabilidades de deserción, proyecciones de matrícula o estimaciones de carga docente. La analítica prescriptiva, el nivel más avanzado, responde a qué debería hacerse: optimización de recursos de retención, asignación de cargas académicas, modelado de escenarios de política institucional antes de su implementación (Ogwuche, 2025).

Un aspecto subrayado en la literatura de 2023–2026 es la necesidad de que los modelos de IA que soportan decisiones institucionales sean interpretables (Explainable AI, XAI): los directivos deben poder comprender por qué un estudiante es clasificado como de alto riesgo, y los tutores deben recibir explicaciones comprensibles sobre las alertas generadas. La opacidad de los modelos —los denominados black boxes— socava la confianza del cuerpo académico y puede derivar en decisiones sin respaldo ético o pedagógico suficiente (Ogwuche, 2025; Tiika et al., 2025). La Tabla 7.2 resume los modelos de solución

disponibles y sus implicaciones institucionales. La Tabla 7.3 amplía esta comparación con características, costos y limitaciones.

Tabla 7.2

Síntesis de plataformas de analítica educativa para IES según modelo tecnológico y soberanía del dato

Modelo de solución	Ejemplos	Implicación institucional
Código abierto o federado	Moodle Analytics; Open Learning Analytics	Mayor soberanía del dato, pero exige capacidades técnicas propias.
SaaS integrado al LMS	Brightspace Insights (D2L)	Facilita implementación y tableros, con dependencia moderada del proveedor.
Plataformas propietarias de retención	EAB Navigate; Civitas Learning	Alta capacidad predictiva y de acompañamiento, con mayor riesgo de lock-in.
Estrategia híbrida recomendada	BI institucional + módulos abiertos + cláusulas de portabilidad	Permite escalamiento gradual, control de datos y adaptación al contexto de ALC.

Nota. Elaboración propia con base en información pública de Moodle, D2L, EAB, Open Learning Analytics y Civitas Learning. La comparación detallada se presenta en la Tabla 7.3.

Tabla 7.3

Comparación detallada de plataformas de analítica educativa para IES: funcionalidades, costos y soberanía del dato

Plataforma	Modelo de licencia	Costo estimado	Integración con SIS/LMS de ALC	Facilidad de uso institucional	Soberanía del dato
Moodle Analytics (Moodle LMS)	Código abierto (PHP)	Gratuito; costos de implementación y soporte	SIS básico vía plugins; REST API	Moderada; requiere equipo técnico	Alta: datos en servidores propios; sin licencia propietaria
Brightspace Insights (D2L)	Propietario (SaaS)	Licencia por usuario; variable según volumen	LMS nativo D2L; conectores con SIS externos	Alta; dashboards preconfigurados	Media: datos en nube D2L; cláusulas de portabilidad revisables
EAB Navigate (EAB)	Propietario (SaaS)	Contrato institucional; coste elevado para IES pequeñas	Banner, PeopleSoft, Salesforce, Canvas, Blackboard	Alta; orientada a consejeros y tutores	Baja-media: alto vendor lock-in; datos gestionados por EAB
Open Learning Analytics (OLA)	Código abierto (xAPI/IMS)	Gratuito; costos de infraestructura propios	xAPI, LTI, estándares abiertos IMS Global	Baja; requiere desarrollo a medida	Muy alta: arquitectura federada; soberanía plena del dato
Civitas Learning	Propietario (SaaS)	Contrato institucional; orientado a universidades grandes	SIS, LMS, sistemas de becas y financiamiento	Alta; modelos predictivos preentrenados	Baja: modelos entrenados con datos de múltiples IES clientes

Nota. Elaboración propia con base en información pública de Moodle, D2L, EAB, Open Learning Analytics y Civitas Learning. Los costos son estimados y pueden variar según el tamaño institucional, el país y las condiciones contractuales.

7.4.4 De la capacidad predictiva a la utilidad institucional

Una precisión metodológica resulta indispensable: el rendimiento estadístico de un modelo no equivale, por sí solo, a utilidad institucional. Una curva ROC elevada o una buena exactitud demuestran capacidad de discriminación, pero no que las alertas sean oportunas, comprensibles ni conducentes a mejores trayectorias. La literatura reciente confirma la consolidación del aprendizaje automático para predecir compromiso, desempeño y abandono, junto con desafíos de transparencia, fundamento pedagógico y viabilidad de implementación (Rodríguez-Ortiz et al., 2025). Por ello, la evaluación debe comenzar con una pregunta sustantiva: ¿qué decisión académica mejora gracias al modelo, para quién y bajo qué condiciones? El marco del NIST refuerza esta orientación al exigir que los riesgos se gobiernen, mapeen, midan y gestionen durante todo el ciclo de vida (Tabassi, 2023).

Un segundo límite es la deriva del modelo. Las relaciones entre asistencia, uso del campus virtual, calificaciones y permanencia cambian cuando se modifica el currículo, se introduce una modalidad híbrida o varía la composición de una cohorte. Un modelo eficaz con datos históricos puede perder calibración en otro semestre, programa o sede; incluso puede conservar una exactitud aceptable y aumentar los falsos positivos en determinados grupos. La investigación sobre predicción temprana bajo deriva conceptual exige evaluar el desempeño entre cohortes y establecer actualizaciones periódicas (Sonnleitner et al., 2025). Las IES deben documentar población y fecha de entrenamiento, validar antes de cada despliegue relevante y comparar sensibilidad, especificidad y calibración por programa y subgrupos pertinentes, cuando su tratamiento sea legal y éticamente justificable.

También debe distinguirse predicción de causalidad. Que una variable anticipe el abandono no significa que intervenir directamente sobre ella produzca permanencia: la baja actividad digital puede expresar problemas de conectividad, sobrecarga laboral o prácticas docentes poco mediadas por tecnología. El modelo debe priorizar una indagación humana, no convertir la correlación en diagnóstico. Su evaluación ha de integrar cuatro planos: calidad y estabilidad técnica; oportunidad y efecto educativo de la intervención; distribución de errores y beneficios entre grupos; y capacidad operativa para atender y cerrar los casos. Solo cuando

los cuatro presentan resultados aceptables puede hablarse de valor institucional; de lo contrario, corresponde rediseñar, limitar o suspender el sistema, aunque sus métricas algorítmicas parezcan competitivas.

7.5 Planeación académica, retención y éxito estudiantil

7.5.1 La retención estudiantil como imperativo institucional en ALC

La deserción universitaria constituye uno de los problemas más complejos y costosos que enfrentan las IES de ALC. La UNESCO estima que entre el 30 % y el 50 % de los estudiantes universitarios en la región no logran completar su carrera (UNESCO, 2023). Las causas son multidimensionales: factores económicos (pobreza, necesidad de trabajo remunerado), académicos (deficiencias de preparación previa, fracaso en primeros cursos), psicosociales (salud mental, sentido de pertenencia) e institucionales (rigidez curricular, ausencia de apoyos pertinentes). La deserción durante el primer semestre es especialmente crítica y concentra el mayor porcentaje de pérdida estudiantil, representando a la vez la ventana de mayor oportunidad para la intervención temprana (Arroyo Montaña et al., 2026; Cuttica, 2025).

La evidencia empírica en ALC ha establecido un hallazgo consistente: las variables disponibles al momento de la matrícula (promedio del bachillerato, puntaje de admisión, nivel socioeconómico) tienen un poder predictivo bajo a moderado respecto de la deserción. La capacidad predictiva mejora de manera significativa una vez que se dispone del rendimiento real en la universidad, en particular el promedio del primer semestre y el número de materias reprobadas. Esto implica que los modelos deben actualizarse de manera continua —a lo largo del trayecto académico del estudiante— en lugar de asumir que el riesgo estimado al ingreso permanece estable (von Hippel & Hofflinger, 2020; Pérez et al., 2025).

7.5.2 El análisis predictivo al servicio de la planeación institucional

La planeación académica habilitada por analítica de datos trasciende la elaboración de reportes históricos para proyectarse hacia la anticipación de escenarios futuros. En el plano operativo, herramientas de aprendizaje automático permiten:

1. Estimar el riesgo de deserción por estudiante, cohorte o programa, y orientar la distribución de recursos de retención hacia la población con mayor probabilidad de beneficiarse de la intervención.

2. Optimizar la oferta de cursos y la asignación de aulas y docentes a partir de proyecciones de demanda basadas en tendencias de matrícula.
3. Modelar el impacto potencial de cambios de política — modificaciones curriculares, ajustes de becas, ampliación de horarios de tutoría— antes de su implementación.
4. Reducir cuellos de botella en los procesos de inscripción, titulación y acceso a servicios de apoyo, mediante agentes inteligentes que anticipan necesidades y automatizan respuestas de rutina.

El Tecnológico de Monterrey (México) ha documentado la gestión de 14,000 consultas estudiantiles mediante asistentes conversacionales inteligentes, con impacto directo en la reducción de tiempos de respuesta y en la experiencia del usuario (MacRae, 2026; UNESCO-ICHEI, 2026). En Colombia, la Universidad Tecnológica de Pereira implementó durante seis años un modelo de SAT que redujo la tasa de deserción del 15 % al 10 %, y cuya experiencia influyó en el diseño de los programas nacionales de fomento a la permanencia del Ministerio de Educación (Ospina et al., 2015).

7.5.3 Cuatro pilares del éxito estudiantil mediado por IA

Un marco de planeación pertinente para las IES de ALC articula cuatro pilares interdependientes a lo largo del trayecto del estudiante:

1. Éxito académico: uso de IA para ofrecer orientación precisa, personalizada y oportuna, asegurando que cada intervención ocurra en el momento en que el estudiante la requiere.
2. Experiencia institucional: reducción de la fricción administrativa mediante sistemas que anticipan necesidades y resuelven cuellos de botella en inscripciones, pagos y servicios de apoyo.
3. Preparación para el mercado laboral: integración de competencias en analítica y ética del dato en el currículo, de modo que el egresado comprenda cómo la tecnología amplifica —y no suplanta— su inteligencia profesional.
4. Innovación operativa: automatización de tareas rutinarias para liberar al personal académico y administrativo hacia el acompañamiento humano de alto valor. La Tabla 7.4 organiza las variables predictivas según su disponibilidad y capacidad explicativa.

Tabla 7.4

Variables predictivas de deserción estudiantil en IES: categorías, disponibilidad y poder predictivo

Categoría	Variables clave	Momento de disponibilidad	Poder predictivo
Preingreso	Promedio bachillerato, puntaje de admisión, nivel socioeconómico	Al momento de matrícula	Bajo–moderado
Primer semestre	Promedio del semestre, cursos reprobados, asistencia	Fin del semestre 1	Moderado–alto
Segundo semestre y más	GPA acumulado, semestres cursados, materias pendientes	Continuo, actualizable	Alto
Comportamiento digital	Accesos al LMS, entrega de tareas, participación en foros	Continuo durante el semestre	Alto en entornos híbridos/virtuales

Nota. Elaboración propia con base en von Hippel y Hofflinger (2020), Pérez et al. (2025) y Arroyo Montaña et al. (2026).

7.6 Sistemas de alerta temprana (SAT)

7.6.1 Definición y lógica de funcionamiento

Los Sistemas de Alerta Temprana (SAT) constituyen la extensión operativa más visible de la analítica predictiva en la gestión académica. Se definen como plataformas que procesan datos de participación, comportamiento y rendimiento académico para identificar situaciones de riesgo con suficiente antelación para que la institución pueda activar intervenciones de apoyo (Bañeres et al., 2019). A diferencia de los informes de diagnóstico retrospectivo, los SAT operan de manera continua durante el semestre, actualizando las estimaciones de riesgo a medida que se incorporan nuevos datos.

La arquitectura básica de un SAT contempla cuatro componentes: (1) captura e integración de datos provenientes del SIS, el LMS y fuentes socioeconómicas; (2) procesamiento mediante modelos de aprendizaje automático; (3) generación y clasificación de alertas por nivel de riesgo, idealmente acompañadas de una justificación interpretable; y (4) protocolos de acción, que determinan quién recibe la alerta, qué tipo de intervención se activa y cómo se registra el seguimiento (Pantin, 2023; Lee, 2025). La Tabla 7.5 resume el ciclo institucional y la Figura 7.1 representa la arquitectura funcional del sistema.

Tabla 7.5

Ciclo estratégico de gestión académica basada en datos

Fase	Acción institucional
1. Integrar	SIS, LMS, ERP, datos externos en repositorio centralizado
2. Analizar	Indicadores de rendimiento, riesgo y comportamiento académico
3. Alertar	Sistema de alertas tempranas con clasificación de riesgo (SAT)
4. Intervenir	Tutores, consejeros y servicios de apoyo activan protocolos
5. Evaluar	Monitoreo de resultados y retroalimentación al modelo predictivo


Nota. Elaboración propia. SIS = Sistema de Información Estudiantil; LMS = Sistema de Gestión del Aprendizaje.

7.6.2 Evidencia de efectividad y condiciones de éxito

La evidencia sobre la efectividad de los SAT es alentadora, pero requiere matices. Estudios reportan mejoras significativas en las tasas de aprobación y retención cuando los sistemas de alerta se integran en ciclos cerrados de acción: en un caso analizado, la activación de un SAT que notificaba a instructores y enviaba listas de riesgo a los asesores antes de que los estudiantes accedieran a servicios universitarios resultó en que el 73 % de los estudiantes en riesgo del grupo experimental obtuvieran calificación aprobatoria (Lee, 2025). Otro sistema reportó incrementos en la tasa de retención del 85 % al 95 % en el lapso de un año (Pantin, 2023).

Sin embargo, la literatura es enfática: el valor institucional de los SAT depende de que las alertas activen acciones concretas. Un estudio ampliamente citado en español señala que los esquemas prometedores integran la identificación temprana con la retroalimentación y el acompañamiento, porque las alertas aisladas generan ruido institucional, fatiga en los tutores o respuestas defensivas; la señal de riesgo se vuelve útil solo cuando dispara una acción breve y pertinente dentro de un ciclo cerrado de predicción, comunicación y seguimiento (Arroyo Montaña et al., 2026).

Figura 7.1. Anatomía de un Sistema de Alerta Temprana (SAT)



7.6.3 SAT en el contexto de ALC: avances y brechas

La adopción de SAT en ALC ha avanzado notablemente en la última década, aunque con marcada heterogeneidad entre países e instituciones. Colombia concentra el mayor volumen de investigación y desarrollo regional en la materia. Un consorcio latinoamericano financiado recientemente —que integra universidades de México, Chile y Argentina— diseñó un proyecto para comparar variables críticas de deserción entre tres contextos distintos, con el objetivo explícito de construir herramientas prácticas utilizables en cada institución, en lugar de imponer un modelo genérico (The HUC, 2023). El estudio de Egoavil Cardenas et al. (2025), que validó un modelo entrenado en universidades peruanas en un dataset externo del Tecnológico de Monterrey obteniendo una exactitud de 0.88, constituye un avance significativo en esta dirección.

No obstante, la brecha entre pilotos y adopción institucional plena persiste. Muchas iniciativas de SAT en ALC permanecen en fase experimental por falta de infraestructura de datos integrada, escasez de personal con competencias analíticas y ausencia de políticas institucionales de gobierno del dato (Asfaw et al., 2023; Márquez et al., 2023). La efectividad del ciclo completo se aprecia en la Figura 7.2.

Figura 7.2. Ciclo institucional de un Sistema de Alerta Temprana (SAT)

Ruta operativa para identificar riesgo estudiantil, activar apoyos y retroalimentar la mejora institucional



7.6.4 De la alerta a la intervención: la última milla institucional

En los SAT, la principal dificultad suele aparecer después de la predicción. Identificar a un estudiante con alta probabilidad de rezago tiene poco efecto si la señal no ingresa en un circuito de atención con responsables, plazos, recursos y criterios de cierre. Esta es la última milla institucional: el tramo que convierte una probabilidad en conversación, apoyo y seguimiento. La evidencia muestra que un modelo generalizable puede detectar tempranamente el riesgo, pero que la mejora depende de cómo se diseña la intervención. En un estudio entre cohortes, las comunicaciones fundamentadas en un enfoque relacional movilizaron a parte de los estudiantes hacia actividades previamente no consultadas, lo que confirma que el contenido y el vínculo importan tanto como la clasificación (Dai et al., 2025).

Cerrar esa distancia exige un flujo explícito. Cada nivel de riesgo debe activar una ruta proporcionada: recursos de autoservicio para situaciones leves, tutoría u orientación cuando confluyen señales y revisión interdisciplinaria para casos complejos. La institución debe definir quién recibe la alerta, en cuánto tiempo contacta, qué información consulta, cómo registra la actuación y cuándo deriva el caso. También debe estimar la capacidad de respuesta antes del despliegue. Si el umbral genera más casos de los que los servicios pueden atender, aparecen fatiga de alertas y competencia por recursos escasos. La alerta, además, debe preservar la agencia del estudiante: explicar la oferta de ayuda, evitar

etiquetas, permitir la corrección de datos y seleccionar la respuesta después de escuchar su contexto.

El impacto debe medirse sobre el ciclo completo y no solo sobre la tasa de aciertos. Conviene registrar cobertura, tiempo de respuesta, aceptación del apoyo, derivaciones completadas y cierre del caso, junto con resultados de aprendizaje y permanencia. Los pilotos escalonados permiten comparar intervenciones sin extender una solución inmadura a toda la institución, mientras la evaluación cualitativa revela si los mensajes se perciben como apoyo, vigilancia o sanción. La UNESCO IESALC (2023) recomienda capacidades internas, marcos de política y participación de la comunidad; y la revisión de Schmidt et al. (2025) confirma la necesidad de examinar las estrategias posteriores a la identificación automatizada. Un SAT madura cuando la institución puede demostrar no solo a quién identificó, sino qué hizo, con qué oportunidad, resultado y resguardos.

7.7 Riesgos de tecnocratización de la gestión educativa

7.7.1 La paradoja del dato abundante

El incremento en la disponibilidad de datos institucionales no garantiza, por sí mismo, mejores decisiones de gestión académica. La literatura de 2023–2026 advierte de manera consistente sobre los riesgos de lo que podríamos denominar la paradoja del dato abundante: la tendencia de las IES a priorizar lo medible por encima de lo formativo, a confundir la generación de indicadores con la generación de evidencia, y a delegar en los algoritmos decisiones que requieren juicio humano, contexto pedagógico e interacción directa (Chigbu & Makapela, 2025).

7.7.2 Sesgo algorítmico y reproducción de desigualdades

El sesgo algorítmico representa uno de los riesgos más serios de la adopción acrítica de IA en la gestión académica. Los modelos de aprendizaje automático aprenden de datos históricos y, en consecuencia, tienden a reproducir —y en muchos casos amplificar— los patrones de desigualdad presentes en esos datos. En el contexto de ALC, donde las IES históricamente han tenido poblaciones estudiantiles estratificadas por clase social, etnia, género y territorialidad, un modelo entrenado sin precauciones puede clasificar sistemáticamente a estudiantes de ciertos perfiles como de alto riesgo no por razones académicas sino por razones estructurales que la institución tiene responsabilidad de transformar, no de perpetuar (Ogwuche, 2025; Tiika et al., 2025).

7.7.3 Vigilancia, privacidad y consentimiento

La analítica de datos estudiantiles implica la recolección y procesamiento de información personal en una escala sin precedentes. Un fenómeno emergente especialmente preocupante en ALC es el denominado shadow AI: el uso de herramientas de IA no provistas ni supervisadas por la institución por parte del personal directivo, académico y administrativo. Cuando datos sensibles de estudiantes se ingresan en plataformas de IA generativa de acceso público, existe el riesgo de que esa información sea utilizada para entrenar modelos externos sin el conocimiento de la institución ni del estudiantado (Spencer, 2024).

7.7.4 Dependencia tecnológica y colonialismo digital

Un riesgo estructural de largo plazo para las IES de ALC es la consolidación de relaciones de dependencia respecto de proveedores tecnológicos privados, en su mayoría con sede en el Norte Global. Cuando las plataformas concentran simultáneamente la infraestructura de datos, los modelos analíticos y los criterios de medición, las instituciones pierden capacidad para auditar, adaptar o disputar las métricas que orientan sus decisiones. Este escenario refuerza formas de dependencia tecnológica y limita la construcción de capacidades regionales propias en analítica educativa.

7.7.5 La tecnocratización como amenaza a la misión educativa

El riesgo más profundo de la gestión académica basada en datos no es técnico sino cultural: la posibilidad de que el imperativo de medir colonice la misión educativa de la universidad. La advertencia de Noam Chomsky, citada en Banda Gamboa (2014), es pertinente aquí: los métodos estadísticos imitan comportamientos sin comprender el significado. Aplicada a la gestión educativa, esta limitación intrínseca de la IA implica que ningún modelo puede capturar la totalidad del proceso pedagógico. Las Tablas 7.6, 7.7 y 7.8 sistematizan las salvaguardas, los marcos normativos y los riesgos principales, mientras que la Figura 7.3 delimita los ámbitos de decisión algorítmica y humana.

Tabla 7.6

Síntesis normativa y salvaguardas institucionales para analítica de datos en IES

Ámbito regulatorio	Exigencia institucional	Implicación para IES de ALC
IA en decisiones de alto impacto	Documentación, supervisión humana y transparencia	No delegar admisión, evaluación o riesgo estudiantil sin trazabilidad y revisión humana.
Protección de datos personales	Consentimiento, minimización de datos y derechos ARCO	Limitar la recolección al propósito académico declarado y auditable.
Gobernanza contractual	Portabilidad, auditoría y seguridad de proveedores	Evitar dependencia tecnológica y asegurar control institucional del dato.
Contestabilidad y rendición de cuentas	Mecanismos para explicar y revisar decisiones algorítmicas	Permitir que estudiantes y docentes cuestionen alertas o clasificaciones automatizadas.

Nota. Elaboración propia con base en los marcos legales y normativos sintetizados en la Tabla 7.7. ARCO = Acceso, Rectificación, Cancelación y Oposición.

Tabla 7.7

Marcos normativos internacionales aplicables a la analítica de datos en instituciones de educación superior

Marco normativo	Jurisdicción	Alcance para IES	Requisitos clave aplicables a analítica de datos	Aplicabilidad directa en ALC	Sanciones relevantes
EU AI Act (UE, 2024)	Unión Europea	IES que usen IA en admisiones, evaluación o gestión de riesgo estudiantil	Documentación obligatoria, supervisión humana, transparencia	Sí (extraterritorial)	Multas de hasta €30 M o 6% del volumen de negocio global
RGPD / GDPR (UE, 2018)	Unión Europea	Datos personales de estudiantes	Consentimiento explícito, minimización de datos, derechos ARCO	Indirecta; referente internacional	Hasta €20 M o 4% del volumen de negocio global
LGPD (Brasil, 2020)	Brasil	Datos personales de estudiantado en IES brasileñas	Bases legales de tratamiento, derechos ARCO, responsable de datos	Sí; marco más robusto de ALC	Multas hasta 2% del ingreso en Brasil
Ley 1581 (Colombia, 2012)	Colombia	Datos personales de estudiantes y personal	Autorización previa, aviso de privacidad, registro nacional	Sí	Multas de hasta 2.000 SMMLV
Ley Federal de Datos Personales (México, 2010)	México	IES privadas y públicas	Principios ARCO, aviso de privacidad, medidas de seguridad	Sí	Multas de hasta 320.000 días de salario mínimo

Nota. Elaboración propia con base en reglamentos y leyes nacionales vigentes. Los marcos normativos están sujetos a modificaciones; se recomienda verificar la legislación nacional vigente antes de su aplicación institucional.




Tabla 7.8

Dimensiones de riesgo en la gestión académica basada en datos: manifestaciones y salvaguardas

Dimensión de riesgo	Manifestación en IES de ALC	Salvaguarda recomendada
Sesgo algorítmico	Modelos entrenados con datos históricos reproducen desigualdades de género, etnia o condición socioeconómica	Auditorías periódicas de equidad; inclusión de variables de contexto; revisión humana obligatoria
Caja negra y opacidad	Directivos no pueden explicar por qué un alumno fue clasificado en riesgo alto	Exigir modelos interpretables (XAI); proveer explicaciones legibles por tutores
Vigilancia y privacidad	Datos de LMS, biometría y geolocalización usados sin consentimiento informado	Políticas de consentimiento claras; marcos de gobernanza de datos aprobados
Dependencia tecnológica	Lock-in con proveedores privados que controlan datos institucionales y definen métricas	Cláusulas contractuales de portabilidad; preferencia por soluciones abiertas o consorciadas
Tecnocratización	Indicadores cuantitativos desplazan criterio pedagógico; se premia lo medible en detrimento de lo formativo	Establecer que los datos informan (no reemplazan) la decisión académica
Colonialismo digital	Datos institucionales de la región entrenan modelos extranjeros; las IES luego compran como servicio lo que generaron	Promover consorcios de datos regionales; apoyar desarrollo de modelos propios

Nota. Elaboración propia con base en Ogwuche (2025), Chigbu y Makapela (2025), Stewart (2023), Bazoobandi et al. (2025) y Rojas Bruna y Calderón Ayala (2025).

7.8 Condiciones institucionales para una gestión académica responsable basada en datos

7.8.1 Gobierno del dato y calidad de la información

Ninguna capacidad analítica puede construirse sobre datos deficientes, fragmentados o sin gobernanza. Las IES de ALC enfrentan una combinación de sistemas desconectados, ausencia de definiciones compartidas de indicadores, duplicación de registros y carencia de políticas explícitas de calidad, acceso y uso del dato. Este es el punto de partida estratégico más urgente: antes de invertir en modelos de IA, las instituciones deben priorizar la integración de sus sistemas de información y el establecimiento de un marco de gobierno del dato que defina responsabilidades, estándares de calidad y procedimientos de actualización (Asfaw et al., 2023; Anderson & Rip, 2019).

La Tabla 7.9 presenta la matriz de madurez institucional en analítica académica, organizada en cinco niveles y cinco dimensiones de evaluación.

Tabla 7.9

Matriz de madurez institucional en analítica académica: cinco niveles y cinco dimensiones de evaluación

Dimensión	Nivel 1 Inicial	Nivel 2 Repetible	Nivel 3 Definido	Nivel 4 Gestionado	Nivel 5 Optimizado
Infraestructura de datos	Datos dispersos en sistemas aislados sin integración	Reportes ad hoc en Excel; analítica manual reactiva	Data warehouse básico; dashboards estáticos por área	Plataforma BI integrada; KPIs en tiempo cuasi real	Ecosistema de datos integrado; analítica en tiempo real con IA
Capacidades humanas	Sin personal con formación analítica formal	1–2 analistas; sin formación institucional sistemática	Equipo analítico constituido; capacitación a directivos básica	Alfabetización analítica generalizada; data literacy en gestión	Comunidad de práctica analítica; innovación y I+D en datos
Gobernanza y política	Sin política de datos ni gobierno definido	Normas informales; sin responsable formal del dato	Política básica de privacidad; primer responsable de datos (DPO)	Marco de gobernanza aprobado; auditorías	Gobernanza participativa; rendición de cuentas algorítmica plena
Cultura analítica	Datos percibidos como carga administrativa	Interés incipiente; iniciativas aisladas sin respaldo directivo	Dirección comprometida; datos usados en algunas decisiones	Cultura de evidencia consolidada; deliberación basada en datos	Innovación continua; retroalimentación sistemática dato–acción
Uso en decisiones	Decisiones basadas en intuición o precedente	Datos consultados ocasionalmente; sin ciclo formal de uso	Analítica descriptiva usada en planeación anual	Analítica predictiva integrada en SAT y asignación de recursos	Analítica prescriptiva; modelado de escenarios de política

Nota. Elaboración propia, adaptada al contexto de la analítica de datos en educación superior, con base en Márquez et al. (2023), Birch (2024) y los marcos de gobernanza examinados en el capítulo.

7.8.2 Alfabetización en datos y cultura analítica

La evidencia del Reino Unido documenta un déficit sectorial de competencias para analizar e interpretar datos, así como una brecha entre

la generación de datos y su uso efectivo en la toma de decisiones, incluso en instituciones con madurez técnica elevada (Birch, 2024). En ALC, donde la madurez técnica de muchas IES es aún menor, este déficit es particularmente pronunciado. La inversión en formación de directivos, coordinadores académicos y personal de bienestar para interpretar y utilizar la información analítica es tan o más estratégica que la inversión en la propia plataforma tecnológica.

7.8.3 Diseño participativo y gobernanza ética

La implementación de sistemas de analítica y SAT requiere la participación activa de la comunidad universitaria —docentes, estudiantes, personal administrativo— en el diseño de las políticas de datos y en la definición de los propósitos para los cuales se utilizará la información. Esta participación no es solo un imperativo ético; es una condición pragmática para la efectividad de los sistemas. Los SAT que se despliegan sin comunicación clara sobre su funcionamiento y sus implicaciones tienden a generar desconfianza y resistencia (Kasope et al., 2024; Stewart, 2023).


Un marco de gobernanza responsable incluye: políticas de consentimiento informado sobre el uso de datos estudiantiles, mecanismos de contestabilidad (right to contest) de las decisiones algorítmicas, auditorías periódicas de sesgo y equidad, y cláusulas contractuales con proveedores que garanticen la soberanía y portabilidad de los datos institucionales.

7.8.4 La centralidad de lo humano en la gestión inteligente

El horizonte deseable para las IES de ALC no es la gestión automatizada, sino la gestión aumentada: instituciones donde la analítica de datos amplía la capacidad de directivos, docentes y tutores para tomar decisiones más informadas, más rápidas y más equitativas, sin desplazar el juicio humano del centro del proceso educativo. Como señala MacRae (2026), el futuro de la educación superior sigue siendo humano, incluso en entornos intensivos en IA. La tecnología tiene el potencial de liberar al personal académico y administrativo de tareas transaccionales para enfocarse en el acompañamiento de alto valor: la mentoría, el asesoramiento vocacional, la orientación psicopedagógica, la deliberación colegiada sobre el currículo. La Figura 7.4 representa este continuo de madurez analítica.

Figura 7.4. Continuum de madurez analítica en instituciones de educación superior

Transición desde reportes descriptivos hasta sistemas autónomos con IA, con énfasis en la situación predominante en América Latina y el Caribe (ALC).



Nota. Elaboración propia con base en el desarrollo del capítulo y en tendencias de madurez analítica en educación superior de ALC.

7.8.5 Ruta institucional de implementación, evaluación y escalamiento

Las condiciones anteriores pueden traducirse en una ruta gradual. La primera fase es de preparación, no de compra tecnológica. Se delimita el problema, la decisión que se pretende apoyar y la línea de base; se inventarían fuentes, responsables, calidad y restricciones de uso; se consulta a los actores afectados; y se verifica si existen servicios capaces de responder. El resultado debe ser un caso de uso acotado, con finalidad legítima, población definida, indicadores de éxito y riesgos previsibles. Esta secuencia coincide con la recomendación de construir ecosistemas digitales confiables, útiles, eficaces y equitativos, antes que colecciones desconectadas de plataformas (OECD, 2023).

La segunda fase es un piloto controlado. Se selecciona un programa limitado, se documenta el modelo y se valida temporalmente con una cohorte distinta de la utilizada para entrenarlo. Personal académico revisa las alertas y registra las razones para confirmarlas, corregirlas o

descartarlas. El piloto prueba también el protocolo de intervención: carga de trabajo, tiempos de contacto, capacidad de derivación y experiencia estudiantil. Para escalar no basta un umbral de exactitud; se requiere generalización, ausencia de brechas injustificadas, respuesta oportuna y beneficio educativo plausible. Cada ampliación debe autorizarse con una ficha de impacto y seguimiento de deriva, errores, desigualdades y reclamaciones. El ciclo de gobernar, mapear, medir y gestionar permite ordenar esta supervisión continua (Tabassi, 2023).

La contratación forma parte de la gobernanza. Los acuerdos deben precisar propiedad y localización de datos, conservación, seguridad, portabilidad, auditoría, incidentes y terminación. La institución necesita documentación suficiente para comprender variables, límites y actualizaciones; la confidencialidad comercial no puede impedir la rendición de cuentas sobre decisiones académicas. En herramientas generativas deben examinarse además la variabilidad, el contenido no sustentado y la protección de información sensible, pues sus beneficios dependen de propósitos pedagógicos claros (OECD, 2026). Para las IES de ALC, repositorios compartidos de protocolos, cláusulas y formación pueden reducir costos, sin sustituir la validación lingüística, curricular y sociocultural local. La madurez se expresa en decidir cuándo usar IA, cuándo limitarla y cuándo prescindir de ella para proteger la misión formativa.

7.9 Síntesis analítica e implicaciones institucionales

El análisis precedente permite identificar tres implicaciones institucionales transversales. Primero, la IA aporta valor a la gestión académica solo cuando se inserta en un sistema de gobierno del dato con definiciones, responsables, estándares de calidad y mecanismos de auditoría. Sin esa base, las plataformas tienden a producir indicadores fragmentados, alertas inconsistentes y decisiones poco confiables.

Segundo, los sistemas de alerta temprana deben ser concebidos como dispositivos de cuidado académico y no como mecanismos de vigilancia. Su legitimidad depende de que cada alerta active un protocolo de apoyo oportuno, proporcional y documentado, con participación de tutores, consejeros y servicios de bienestar. La señal algorítmica debe iniciar una conversación institucional, no cerrar la deliberación pedagógica.

Tercero, la adopción de analítica educativa en ALC requiere una estrategia de soberanía del dato. Las instituciones deben combinar soluciones abiertas, cláusulas contractuales de portabilidad, capacitación interna y cooperación interuniversitaria para evitar que la dependencia

tecnológica transforme los datos de estudiantes y docentes en un recurso controlado por proveedores externos. La gestión inteligente, por tanto, no equivale a automatización plena, sino a una ampliación responsable de la capacidad humana para decidir con evidencia.

7.10 CONCLUSIONES

La gestión académica basada en datos e inteligencia artificial representa, para las IES de América Latina y el Caribe, una oportunidad estratégica y un desafío institucional de gran complejidad. Las posibilidades son reales: los sistemas de alerta temprana pueden anticipar situaciones de riesgo con antelación suficiente para que las intervenciones sean efectivas; la analítica predictiva puede orientar la distribución de recursos de retención hacia quienes más se beneficiarán de ellos; los tableros de control pueden poner a disposición de directivos información integrada y actualizada para sostener la planeación estratégica sobre bases empíricas.

Sin embargo, la literatura de 2023–2026 es inequívoca en señalar que estas posibilidades se realizan únicamente cuando se dan ciertas condiciones: sistemas de información integrados y datos de calidad, capacidades analíticas en los equipos humanos, marcos de gobernanza participativa y ética, y diseños que preserven la centralidad del juicio pedagógico en las decisiones de alto impacto. En ausencia de estas condiciones, la adopción de IA en la gestión universitaria corre el riesgo de reproducir y amplificar desigualdades, erosionar la confianza institucional y derivar en la tecnocratización de procesos que tienen, en su núcleo, una dimensión profundamente humana.

Para las IES de ALC, la hoja de ruta más prometedora no pasa por la acumulación acelerada de herramientas de IA, sino por el fortalecimiento de las bases: gobierno del dato, integración de sistemas, formación de capacidades analíticas en los equipos institucionales y construcción participativa de marcos éticos que subordinen la tecnología al propósito formativo de la universidad. El dato, la información, el conocimiento y la sabiduría aplicada solo emergen cuando hay personas capaces de interpretarlos, cuestionarlos y traducirlos en acciones pertinentes para cada comunidad académica concreta. Esta hoja de ruta de fortalecimiento institucional sienta las bases para el análisis de experiencias concretas que se presenta en el Capítulo 9, donde se examinan estudios de caso y modelos emergentes de rediseño formativo inteligente en la región.

7.11 REFERENCIAS BIBLIOGRÁFICAS

- Anderson, R., & Rip, N. (2019). From data crisis to data-centric. AIR Professional File. <https://doi.org/10.34315/apf1452019>
- Arroyo Montaña, M. L., Tenorio Canchingre, E. Y., Mendoza Hernández, S. S., et al. (2026). Barreras de ingreso, IA predictiva y estrategias innovadoras de retención estudiantil en educación superior de Esmeraldas. ASCE Magazine, 5(1). <https://doi.org/10.70577/asce.v5i1.682>
- Asfaw, Z., Alemneh, D., Jimma, W., & Ferede, B. (2023). Data-driven decision-making practice in higher education institutions in Ethiopia. Proceedings of the Association for Information Science and Technology. <https://doi.org/10.1002/ptra2.882>
- Banda Gamboa, H. A. (2014). Inteligencia artificial: Principios y aplicaciones. Escuela Politécnica Nacional.
- Bañeres, D., Karadeniz, A., Guerrero-Roldán, A.-E., et al. (2019). Analysis of the accuracy of an early warning system for learners at-risk: A case study. EDULEARN19 Proceedings. <https://doi.org/10.21125/EDULEARN.2019.0401>
- Bazoobandi, S., Mahapatra, S., Schipper, T., & Wiecek, I. (2025). From global governance to nationalism: The future of AI (No. 2). German Institute for Global and Area Studies.
- Birch, K. (2024). Turning universities into data-driven organisations: Seven dimensions of change. Higher Education. <https://doi.org/10.1007/s10734-024-01277-z>
- Chigbu, B. I., & Makapela, S. (2025). Data-driven leadership in higher education: Advancing sustainable development goals and inclusive transformation. Sustainability, 17(7), Article 3116. <https://doi.org/10.3390/su17073116>
- Cuttica, M. A. (2025). Prevención del abandono en la educación superior: Diseño de un sistema de alerta temprana. Gestión de la Educación, 11(2). <https://doi.org/10.15517/jcmvaj47>
- Dai, W., Lin, J., Jin, F. J.-Y., Tsai, Y.-S., Srivastava, N., Le Bodic, P., Gašević, D., & Chen, G. (2025). Learning analytics for early identification of at-risk students and feedback intervention. Journal of Learning Analytics, 12(3), 102–125. <https://doi.org/10.18608/jla.2025.8735>
- Egoavil Cardenas, G. A., Ruiz Pachamango, I. Y., Prado Ventocilla, A. J., & Montes Eskenazy, E. J. (2025). Building generalizable models for student retention: A multi-source validation framework for the Peruvian higher education context. 2025 IEEE XXXII International Conference on Electronics, Electrical Engineering and Computing (INTERCON). <https://doi.org/10.1109/INTERCON67304.2025.11244379>
- Gaftandzhieva, S. N., Hussain, S., Hilčenko, S., et al. (2023). Data-driven decision making in higher education institutions: State-of-play. International Journal of Advanced Computer Science and Applications. <https://doi.org/10.14569/ijacsa.2023.0140642>
- Kasope, W., Elugbaju, W. K., Okeke, N. I., & Alabi, O. (2024). Conceptual framework for enhancing decision-making in higher education through data-driven governance. Global Journal of Advanced Research and Reviews. <https://doi.org/10.58175/gjarr.2024.2.2.0055>
- Lee, C.-I. (2025). Developing an early warning system with personalized interventions to enhance academic outcomes for at-risk students in Taiwanese higher education. Education Sciences, 15(10), Article 1321. <https://doi.org/10.3390/educsci15101321>
- MacRae, S. (2026). The future is human – even with AI. Ithaca College News.

- Márquez, L., Henríquez, V., Chevreux, H., et al. (2023). Adoption of learning analytics in higher education institutions: A systematic literature review. *British Journal of Educational Technology*. <https://doi.org/10.1111/bjet.13385>
- Ogwuche, A. O. (2025). Transforming academic planning and administration with artificial intelligence: Implications for student learning interest in universities. *Education & Learning in Developing Nations*. <https://doi.org/10.26480/eldn.02.2025.100.109>
- OECD. (2023). *OECD Digital Education Outlook 2023: Towards an effective digital education ecosystem*. OECD Publishing. <https://doi.org/10.1787/c74f03de-en>
- OECD. (2026). *OECD Digital Education Outlook 2026: Exploring effective uses of generative AI in education*. OECD Publishing. <https://doi.org/10.1787/062a7394-en>
- Ospina, D., Gómez, S., & Rojas, M. (2015). Estrategias de permanencia estudiantil en la educación superior: Una experiencia en la Universidad Tecnológica de Pereira. Universidad Tecnológica de Pereira.
- Pantin, R. (2023). Developing a dynamic decision-support framework for higher education management systems through real-time information extraction. *International Conference on Future Networks and Distributed Systems*. <https://doi.org/10.1145/3644713.3644786>
- Pérez, M., Navarrete, D., Baldeon Calisto, M. G., et al. (2025). Unlocking student success: Applying machine learning for predicting student dropout in higher education. *International Symposium on Digital Forensics and Security*. <https://doi.org/10.1109/ISDFS65363.2025.11012013>
- Rodríguez-Ortiz, M. Á., Santana-Mancilla, P. C., & Anido-Rifón, L. E. (2025). Machine learning and generative AI in learning analytics for higher education: A systematic review of models, trends, and challenges. *Applied Sciences*, 15(15), Article 8679. <https://doi.org/10.3390/app15158679>
- Rojas Bruna, C., & Calderón Ayala, C. (2025). Co-construcción e inteligencia artificial en la gestión docente: Un estudio de caso en Chile. *Gestión de la Educación*. <https://doi.org/10.15517/3rtsn163>
- Schmidt, A., Cechinel, C., Queiroga, E. M., Primo, T., Ramos, V., Bordin, A. S., Mello, R. F., & Muñoz, R. (2025). Analyzing intervention strategies employed in response to automated academic-risk identification: A systematic review. *IEEE Revista Iberoamericana de Tecnologías del Aprendizaje*, 20, 77–85. <https://doi.org/10.1109/RITA.2025.3540161>
- Sharma, H. S., & Joshi, H. D. (2022). Pooling business intelligence and dashboard technology for decision making in higher education institutions. *Towards Excellence*. <https://doi.org/10.37867/te140306>
- Sonnleitner, B., Madou, T., Deceuninck, M., Theodosiou, F., & Sagaert, Y. R. (2025). Evaluation of early student performance prediction given concept drift. *Computers and Education: Artificial Intelligence*, 8, Article 100369. <https://doi.org/10.1016/j.caeai.2025.100369>
- Spencer, P. (2024). Critical AI data governance gap in higher education. *Kiteworks*. <https://www.kiteworks.com/cybersecurity-risk-management/>
- Stewart, B. (2023). Barriers and beliefs: A comparative case study of how university educators understand the datafication of higher education systems. *International Journal of Educational Technology in Higher Education*. <https://doi.org/10.1186/s41239-023-00402-9>

- Tabassi, E. (2023). Artificial Intelligence Risk Management Framework (AI RMF 1.0) (NIST AI 100-1). National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.AI.100-1>
- The HUC. (2023). Tres universidades latinoamericanas utilizarán IA para prevenir la deserción estudiantil en la educación superior. <https://thehuc.org/tres-universidades-latinoamericanas-utilizaran-ia-para-prevenir-la-desercion-estudiantil/>
- Tiika, B. J., Lotsu, S., & Buame, J. A. (2025). The role of AI in shaping the discharge of duties of university administrators: A systematic review. *Pan-African Journal of Education and Social Sciences*. <https://doi.org/10.56893/pajes2025v06i02.02>
- UNESCO. (2023). Informe de seguimiento de la educación en el mundo 2023. UNESCO.
- UNESCO IESALC. (2023). Harnessing the era of artificial intelligence in higher education: A primer for higher education stakeholders. UNESCO International Institute for Higher Education in Latin America and the Caribbean. <https://unesdoc.unesco.org/ark:/48223/pf0000386670>
- UNESCO-ICHEI. (2026). Insights on the digital transformation of higher education: An overview of changes in Latin America. UNESCO IESALC.
- von Hippel, P. T., & Hofflinger, Á. (2020). The data revolution comes to higher education: Identifying students at risk of dropout in Chile. *Journal of Higher Education Policy and Management*. <https://doi.org/10.1080/1360080X.2020.1739800>