

Educación basada en datos

Learning Analytics para mejorar el rendimiento académico y la gestión universitaria



AUTORES

Velasco-Holguin, Nefer Paulette; Alarcón-Anco, Ronald Jesús;
Alcívar-Cuenca, Patricio Eli; García-Lino, Maritza Elizabeth;
Ramos-Zapata, Angela Lucero; Araujo-Criollo, Marcos Daniel;
Dávila-Alva, Emerson; Chang-Gómez, Mario Andrew;
Reategui-Noriega, Eddir Erick; Guerrero-Zambrano, Marcos Francisco



OM
EDITORIAL

**Educación basada en datos.
Learning Analytics para mejorar el
rendimiento académico y la gestión
universitaria.**

Autor/es:

Velasco Holguin Nefer Paulette

Investigadora independiente

Alarcon Anco Ronald Jesús

Universidad Nacional Mayor de San Marcos

Alcívar Cuenca Patricio Eli

Universidad Estatal Península de Santa Elena

García Lino Maritza Elizabeth

Universidad Técnica Luis Vargas Torres de Esmeraldas

Ramos Zapata Angela Lucero

Universidad Nacional Mayor de San Marcos

Araujo Criollo Marcos Daniel

Universidad Agraria del Ecuador

Dávila Alva Emerson

Universidad Nacional de la Amazonía Peruana

Chang Gómez Mario Andrew

Universidad Nacional de la Amazonía Peruana

Reategui Noriega Eddir Erick

Universidad Nacional de la Amazonía Peruana

Guerrero Zambrano Marcos Francisco

Universidad Estatal de Milagro

Datos de Catalogación Bibliográfica

Velasco-Holguín, N. P.
Alarcón-Anco, R. J.
Alcívar-Cuenca, P. E.
García-Lino, M. E.
Ramos-Zapata, A. L.
Araujo-Criollo, M. D.
Dávila-Alva, E.
Chang-Gómez, M. A.
Reategui-Noriega, E. E.
Guerrero-Zambrano, M. F.

Educación basada en datos. Learning Analytics para mejorar el rendimiento académico y la gestión universitaria.

Oriente-Manabí Editorial, Ecuador, 2026

ISBN: 978-9907-9567-0-2

Formato: 210 mm X 270 mm

83 págs.



Publicado por Oriente-Manabí Editorial

Ecuador, Manabí, Cod. Post. 130101.

Contacto: +593 959 723 343

Email: info@omeditorial.com

www.books.omeditorial.com

Director General:	<i>Dr. Guerrero Bermúdez Ángel Enrique</i>
Editor en Jefe:	<i>Dr. Guerrero Bermúdez Ángel Enrique</i>
Editor Académica:	<i>Lcdo. Oltramonti Roberto, Mg</i>
Supervisor de Producción:	<i>Ing. Barragán Monrroy Roberto Johan, Mg.</i>
Diseño:	OM Editorial
Consejo Editorial	<i>OM Editorial</i>

© Julio, 2026

Libro Digital, Primera Edición, 2026

Editado, Diseñado, Diagramado y Publicado por [Comité OM Editorial](#)

Manabí, Ecuador, 2026

D.R. © 2026 por Autores y OM Editorial Ecuador.

Cámara Ecuatoriana del Libro con Radicación editorial 182865

Disponible para su descarga gratuita en www.books.omeditorial.com

Los contenidos de este libro pueden ser descargados, reproducidos, difundidos e impresos con fines de estudio, investigación y docencia o para su utilización en productos o servicios no comerciales, siempre que se reconozca adecuadamente a los autores como fuente y titulares de los derechos de propiedad intelectual, sin que ello implique en modo alguno que aprueban las opiniones, productos o servicios resultantes. En el caso de contenidos que indiquen expresamente que proceden de terceros, deberán dirigirse a la fuente original indicada para gestionar los permisos.

Título del libro:

Educación basada en datos. Learning Analytics para mejorar el rendimiento académico y la gestión universitaria.

© Velasco-Holguin, Nefer Paulette; Alarcón-Anco, Ronald Jesús; Alcívar-Cuenca, Patricio Eli; García-Lino, Maritza Elizabeth; Ramos-Zapata, Angela Lucero; Araujo-Criollo, Marcos Daniel; Dávila-Alva, Emerson; Chang-Gómez, Mario Andrew; Reategui-Noriega, Eddir Erick; Guerrero-Zambrano, Marcos Francisco.

ISBN: 978-9907-9567-0-2



<https://doi.org/10.63618/omeditorial/I25>

Como citar (APA 7ma Edición):

Velasco-Holguin, N. P., Reategui-Noriega, E. E., Chang-Gómez, M. A., Dávila-Alva, E., Araujo-Criollo, M. D., Ramos-Zapata, A. L., García-Lino, M. E., Alcívar-Cuenca, P. E., Alarcon-Anco, R. J., & Guerrero-Zambrano, M. F. (2026). *Educación basada en datos. Learning Analytics para mejorar el rendimiento académico y la gestión universitaria*. Oriente-Manabí Editorial. <https://doi.org/10.63618/omeditorial/I25>

Cada uno de los textos de OM Editorial han sido sometido a un proceso de evaluación por pares doble ciego externos (double-blind paper review) con base en la normativa del editorial.

Revisores:



Ing. Juan Manuel Guerrero
Calero, PhD

Universidad Estatal del Sur de
Manabí – Ecuador



Lcdo. Yasiel Barban Forte, Mg

Instituto Superior Tecnológico
Crecermas – Ecuador
Pontificia Universidad Católica
del Ecuador – Ecuador



Aviso Legal:

La información presentada, así como el contenido, fotografías, gráficos, cuadros, tablas y referencias de este manuscrito es de exclusiva responsabilidad del/los autores/es y no necesariamente reflejan el pensamiento de la OM Editorial.

Derechos de autor ©

Este documento se publica bajo los términos y condiciones de la licencia Creative Commons Reconocimiento-No Comercial-Compartir Igual 4.0 Internacional (CC BY-NC-SA 4.0).



El "copyright" y todos los derechos de propiedad intelectual y/o industrial sobre el contenido de esta edición son propiedad de la OM Editorial y sus Autores. Se prohíbe rigurosamente, bajo las sanciones en las leyes, la producción o almacenamiento total y/o parcial de esta obra, ni su tratamiento informático de la presente publicación, incluyendo el diseño de la portada, así como la transmisión de la misma de ninguna forma o por cualquier medio, tanto si es electrónico, como químico, mecánico, óptico, de grabación o bien de fotocopia, sin la autorización de los titulares del copyright, salvo cuando se realice con fines académicos o científicos y estrictamente no comerciales y gratuitos, debiendo citar en todo caso a la editorial. Las opiniones expresadas en los capítulos son responsabilidad de los autores

Reseña de Autores



Velasco-Holguin, Nefer Paulette



Investigadora independiente



nefer010200@gmail.com



<https://orcid.org/0009-0008-8238-3514>



Ingeniera ambiental, Magister en gestión de riesgo e investigadora independiente ecuatoriana comprometida con la generación de conocimiento científico y la sostenibilidad. Cuento con una trayectoria de 3 años en investigación académica, gestión ambiental y educación superior. He participado en publicaciones científicas y proyectos de impacto social, destacándome por el interés en la innovación, la gestión de riesgos y el desarrollo de soluciones orientadas al bienestar comunitario.



Alarcon-Anco, Ronald Jesús



Universidad Nacional Mayor de San Marcos



ronald.alarcona@unmsm.edu.pe



<https://orcid.org/0000-0002-7971-5302>



Abogado y licenciado en Educación. Posee maestrías en Docencia Universitaria y Gestión Educativa, así como en Filosofía e Investigación. Es Doctor en Administración, PhD in Business Administration. Se desempeña como profesor universitario en pregrado y posgrado en la UNMSM y en diversas universidades del Perú e internacionales. Investigador RENACYT-P0051760, consultor en Derechos humanos, Defensa nacional, consultor en inteligencia artificial aplicada al derecho de la empresa y la educación. Cuenta con amplia experiencia como asesor y consultor en temas jurídicos, DDHH, Derecho Constitucional derecho Empresarial y Derecho Educativo. Conferencista en gestión legal, empresarial y sistemas educativos.



Alcívar-Cuenca, Patricio Eli



Universidad Estatal Península de Santa Elena



patricio.alcivar@upse.edu.ec



<https://orcid.org/0009-0005-3618-9380>



Ingeniero en Sistemas, Magíster en Ingeniería de Software, Ciberseguridad y DevOps, y docente investigador en la Universidad Estatal Península de Santa Elena (UPSE). Su labor se centra en la intersección del desarrollo de software avanzado y la transformación educativa mediante el uso de tecnologías emergentes. Con una sólida base técnica en arquitectura de sistemas y análisis de datos, ha contribuido en investigaciones publicadas en revistas indexadas sobre la "Educación 5.0", explorando el impacto de la Inteligencia Artificial y el humanismo en las dinámicas universitarias. Busca optimizar el rendimiento académico y la gestión universitaria a través de soluciones tecnológicas innovadoras y basadas en datos.



García-Lino, Maritza Elizabeth



Universidad Técnica Luis Vargas Torres de Esmeraldas



maritza.garcia.lino@utelvt.edu.ec



<https://orcid.org/0000-0001-9005-4915>



Maritza Elizabeth García Lino, Ingeniera química con maestría en seguridad y salud ocupacional y didáctica de la física y la química. Actualmente me desempeño como docente en la Universidad Técnica Luis Vargas Torres de Esmeraldas formando profesionales comprometidos con la excelencia técnica y la responsabilidad social. En vinculación con la sociedad he desarrollado capacitaciones continuas en seguridad alimentaria, buen manejo de desechos y recurso agua, programas formativos diseñados para fortalecer las capacidades de comunidades en prácticas esenciales para la salud pública y la sostenibilidad ambiental.



Ramos-Zapata, Angela Lucero



Universidad Nacional Mayor de San Marcos



ange.to2012@gmail.com



<https://orcid.org/0000-0002-5618-8570>



La Mg. Angela Ramos Zapata es Licenciada en Tecnología Médica, especialista en Terapia Ocupacional y docente en la UNMSM y UPCH. Posee maestrías en Educación y Neuropedagogía, y cursa un doctorado en Educación. Tiene amplia experiencia en investigación, neurorrehabilitación y neurodesarrollo. Actualmente, integra la junta directiva de la Asociación Científica de Terapia Ocupacional (ACITO) y el comité ad hoc del Colegio de Tecnólogos Médicos del Perú. Asimismo, se desempeña como coordinadora de Terapia Ocupacional en la consultora Mentes Diversas y difunde activamente su profesión creando contenido educativo a través de la plataforma T.O. EDUCA.



Araujo-Criollo, Marcos Daniel



Universidad Agraria del Ecuador (UAE)



maraujo@uagraria.edu.ec



<https://orcid.org/0009-0005-2240-9266>



Ingeniero Agropecuario por la Escuela Politécnica del Ejército (ESPE) y Magíster en Gerencia de la Calidad e Innovación por la Universidad Internacional del Ecuador (UIDE). Trayectoria profesional en los sectores agropecuario y agroindustrial, desempeñándose en áreas de control de calidad, inocuidad alimentaria, auditorías técnicas, gestión de procesos y mejora continua. Durante ocho años formó parte de la Agencia de Control Fitosanitaria y Zoonosanitaria del Ecuador (Agrocalidad), participando en: registro y evaluaciones técnicas de productos agropecuarios, inspecciones y procesos regulatorios vinculados a la calidad e inocuidad. Ha trabajado en administración y gestión de sistemas productivos, en cadenas de valor relacionadas con producción agrícola y ganadera. Actualmente es docente universitario a tiempo completo en la Universidad Agraria del Ecuador (UAE) con actividades de: Docencia, Investigación con interés en: Learning Analytics, Innovación, Desarrollo de productos, Nutrición Animal, Trazabilidad Agroalimentaria e Inteligencia Artificial Aplicada para la educación y el sector productivo.



Dávila-Alva, Emerson



Universidad Nacional de la Amazonía
Peruana



emersondavila17@gmail.com



<https://orcid.org/0009-0004-6085-7978>



Ingeniero Químico Colegiado egresado de la Universidad Nacional de la Amazonía Peruana, Magíster en Ciencias y Tecnologías Ambientales con mención en Seguridad y Medio Ambiente en la Industria de Hidrocarburos. Cuenta con más de 15 años de experiencia en el sector Oil & Gas en inspección, operación y seguridad de instalaciones de exploración, producción, plantas de procesamiento y oleoductos. Especialista en normas NFPA, ANSI, OSHA e ISO 14000, y consultor en Sistemas Integrados de Gestión, Seguridad Industrial y Protección Ambiental. Su enfoque en la gestión basada en datos lo motivó a desarrollar esta obra como aporte a la mejora continua de la educación superior.



Chang-Gómez, Mario Andrew



Universidad Nacional de la Amazonía
Peruana



mario.chang@unapiquitos.edu.pe



<https://orcid.org/0009-0003-4287-5868>



Ingeniero Químico egresado de la Universidad Nacional de la Amazonía Peruana (UNAP), Magíster en Ciencias y Tecnologías Ambientales (mención Industria del Petróleo y Medio Ambiente) y Candidato a Doctor en Ciencias Ambientales por la misma casa de estudios. Docente contratado en la Facultad de Ingeniería Química (FIQ-UNAP), donde imparte Química General, Química Inorgánica y Biofísica. Su experiencia en el aula universitaria lo condujo a interesarse en el análisis de datos académicos como recurso para comprender y mejorar los procesos de enseñanza-aprendizaje, dando origen a esta obra sobre Learning Analytics aplicado a la mejora del rendimiento académico y la gestión universitaria.



Reategui-Noriega, Eddir Erick



Universidad Nacional de la Amazonía
Peruana



eddir.reategui@unapiquitos.edu.pe



<https://orcid.org/0009-0003-8364-1304>



Ingeniero Químico y Magíster en Gestión Ambiental por la Universidad Nacional de la Amazonía Peruana (UNAP). Docente contratado en la Facultad de Ingeniería Química (FIQ-UNAP), con experiencia en la enseñanza de Química General, Química Inorgánica y Biofísica. Su práctica docente universitaria lo llevó a explorar el uso de datos e indicadores académicos como herramientas para la mejora del aprendizaje y la gestión educativa, motivando el desarrollo de esta obra orientada a la aplicación del Learning Analytics en la educación superior.



Guerrero-Zambrano, Marcos Francisco.



Universidad Estatal de Milagro



mguerreroz@unemi.edu.ec



<https://orcid.org/0000-0002-5617-6836>



Marcos Francisco Guerrero Zambrano es docente e investigador de la Universidad Estatal de Milagro, con trayectoria académica vinculada a la educación científica. Es Doctor en Educación en Ciencias Experimentales, Magíster en Enseñanza de la Física, cursa estudios en Magister en Inteligencia Artificial Aplicada a la Educación y es Ingeniero en Electricidad con mención en Automatización. Su trabajo se centra en la didáctica de la Física, tecnologías emergentes, TIC, laboratorios remotos, inteligencia artificial, robótica y metodologías activas. Además, ha publicado estudios sobre pensamiento crítico, formación docente y enseñanza de las ciencias.

Índice

Reseña de Autores.....	vi
Índice	xvi
Índice de Tablas	xix
Índice de Figuras	xx
Introducción	xxi
Capítulo I: Fundamentos de la educación basada en datos en la universidad contemporánea	1
1.1. La universidad ante la cultura de datos.....	2
1.1.1. Del dato administrativo al dato pedagógico	4
1.1.2. Educación basada en datos: concepto, alcances y límites.....	5
1.2. Learning Analytics como campo de conocimiento	7
1.2.1. Evolución de Learning Analytics en educación superior.....	9
1.2.2. Diferencias entre Learning Analytics, Educational Data Mining y Academic Analytics	11
1.3. Rendimiento académico como construcción multidimensional.....	13
1.3.1. Indicadores académicos, trayectorias y señales tempranas	15
1.3.2. Aporte de Learning Analytics a la literatura en educación superior	17
Capítulo II: Datos, plataformas e inteligencia analítica para comprender el aprendizaje universitario	20
2.1. Fuentes de datos en los ecosistemas universitarios digitales	21
2.1.1. LMS, interacción digital y trazas de aprendizaje.....	23
2.1.2. Integración de datos académicos, administrativos y pedagógicos	25
2.2. Niveles de analítica: descriptiva, diagnóstica, predictiva y prescriptiva	27

2.2.1.	Analítica descriptiva y diagnóstica del desempeño académico ...	29
2.2.2.	Analítica predictiva y sistemas de alerta temprana.....	31
2.3.	Dashboards académicos y visualización de información.....	33
2.3.1.	Indicadores visuales para docentes y gestores	35
2.3.2.	Riesgos de interpretación y sobredependencia de los tableros ..	37
Capítulo III: Learning Analytics para mejorar el rendimiento académico y las trayectorias estudiantiles.....		39
3.1.	Del análisis del rendimiento a la intervención educativa.....	40
3.1.1.	Evaluación formativa apoyada en analítica del aprendizaje	42
3.1.2.	Retroalimentación personalizada y mejora del desempeño	44
3.2.	Aprendizaje adaptativo y rutas diferenciadas.....	46
3.2.1.	Variables para personalizar el aprendizaje universitario	48
3.2.2.	Diseño instruccional basado en evidencias analíticas.....	49
3.3.	Permanencia, inclusión y acompañamiento estudiantil	51
3.3.1.	Tutorías académicas orientadas por datos	53
3.3.2.	Riesgo académico, abandono y respuesta institucional temprana	54
Capítulo IV: Gestión universitaria, ética y gobernanza de Learning Analytics ..		57
4.1.	Gestión universitaria basada en evidencia.....	58
4.1.1.	Indicadores institucionales para la mejora académica	60
4.1.2.	Calidad, acreditación y mejora continua apoyadas en Learning Analytics.....	62
4.2.	Gobernanza de datos educativos.....	63
4.2.1.	Privacidad, consentimiento y protección de datos estudiantiles..	65
4.2.2.	Sesgos algorítmicos, justicia educativa y supervisión humana ...	67
4.3.	Modelo integral para implementar Learning Analytics en educación superior	69

4.3.1.	Condiciones institucionales para una implementación sostenible	7
1		
4.3.2.	Agenda futura de investigación y aporte del libro	73
	Referencias Bibliográficas	75

Índice de Tablas

Tabla 1. Tipos de datos universitarios y usos educativos	5
Tabla 2. Evolución de Learning Analytics	11
Tabla 3. Comparación entre campos analíticos.....	13
Tabla 4. Indicadores de alerta académica	17
Tabla 5. Trazas digitales y posibles lecturas pedagógicas.....	25
Tabla 6. Usos de la analítica descriptiva y diagnóstica	31
Tabla 7. Indicadores visuales por usuario institucional	37
Tabla 8. Indicadores para evaluación formativa	44
Tabla 9. Variables de personalización académica	49
Tabla 10. Decisiones de diseño instruccional basadas en datos	50
Tabla 11. Uso de datos en tutorías universitarias	54
Tabla 12. Indicadores institucionales de mejora académica	62
Tabla 13. Criterios éticos para uso de datos estudiantiles	67
Tabla 14. Condiciones para implementar Learning Analytics	72

Índice de Figuras

Figura 1. Ecosistema universitario basado en datos	3
Figura 2. Componentes conceptuales de Learning Analytics.....	8
Figura 3. Dimensiones del rendimiento académico universitario	15
Figura 4. Mapa de fuentes de datos universitarios	23
Figura 5. Escalera de madurez analítica universitaria.....	29
Figura 6. Ciclo de alerta temprana responsable	33
Figura 7. Arquitectura de Dashboard académico	35
Figura 8. Ruta dato–interpretación–intervención–mejora.....	42
Figura 9. Modelo de aprendizaje adaptativo basado en datos	47
Figura 10. Analítica para la permanencia inclusiva	52
Figura 11. Sistema de respuesta temprana al abandono.....	56
Figura 12. Modelo de gestión universitaria basada en evidencia.....	60
Figura 13. Marco de gobernanza de datos para Learning Analytics	65
Figura 14. Ciclo de supervisión ética de modelos analíticos	68
Figura 15. Ruta institucional de implementación de Learning Analytics	70
Figura 16. Agenda futura de Learning Analytics en educación superior	74

Introducción

La educación superior atraviesa un momento decisivo, marcado por transformaciones tecnológicas, nuevas demandas sociales y una creciente necesidad de tomar decisiones más oportunas, pertinentes y sostenibles. Las universidades ya no solo gestionan aulas, programas académicos y procesos administrativos, sino que también conviven con una cantidad cada vez mayor de datos generados por plataformas virtuales, sistemas académicos, registros de evaluación, trayectorias estudiantiles, procesos de matrícula, permanencia, titulación y seguimiento institucional. Esta realidad abre una oportunidad relevante para comprender con mayor precisión lo que ocurre en la vida académica de los estudiantes y en la gestión universitaria, aunque también plantea una exigencia profunda: aprender a interpretar esos datos con inteligencia pedagógica, responsabilidad ética y sentido humano.

En este escenario, los datos no pueden entenderse como simples números acumulados en sistemas digitales, porque su valor no depende únicamente de la cantidad de información disponible, sino de la capacidad institucional para convertirla en conocimiento útil, contextualizado y orientado a la mejora. Una universidad puede disponer de múltiples indicadores y, aun así, tomar decisiones poco pertinentes si no cuenta con criterios claros para leerlos, contrastarlos y vincularlos con la realidad de sus estudiantes. Por ello, la educación basada en datos no debe confundirse con una administración automatizada de la vida universitaria, sino asumirse como una forma más rigurosa, reflexiva y responsable de acompañar el aprendizaje, fortalecer la gestión y anticipar necesidades educativas.

Learning Analytics surge en este contexto como un campo estratégico para analizar, comprender y mejorar los procesos de aprendizaje mediante el uso organizado de datos educativos, pero su propósito no se limita a medir el rendimiento académico ni a producir reportes institucionales. Su aporte más significativo está en la posibilidad de identificar patrones, reconocer dificultades, observar trayectorias, valorar interacciones y generar información significativa para apoyar decisiones pedagógicas e institucionales. En la educación superior, su importancia radica en que permite mirar más allá de los resultados finales y

aproximarse a los procesos que explican cómo aprenden los estudiantes, qué obstáculos enfrentan y qué condiciones favorecen o limitan su desempeño.

La mejora del rendimiento académico constituye uno de los ámbitos más visibles de aplicación de Learning Analytics, especialmente porque el análisis de información sobre participación, avance en actividades, desempeño en evaluaciones, asistencia, interacción con recursos y comportamiento académico puede ayudar a detectar señales tempranas de riesgo. Esta posibilidad no debe entenderse como una forma de etiquetar al estudiante ni de anticipar su futuro como si estuviera cerrado, sino como una oportunidad para intervenir antes de que las dificultades se conviertan en abandono, rezago o fracaso académico. Desde esta mirada, el análisis de datos puede transformarse en una herramienta de acompañamiento, siempre que esté al servicio de la permanencia, la inclusión y el aprendizaje significativo.

Además de su aporte pedagógico, Learning Analytics posee una dimensión relevante para la gestión universitaria, ya que las decisiones sobre currículo, oferta académica, tutorías, asignación de recursos, evaluación docente, seguimiento de cohortes, procesos de acreditación y mejora continua pueden fortalecerse cuando se apoyan en evidencias organizadas y comprensibles. Una institución que analiza responsablemente sus datos está en mejores condiciones de reconocer brechas, anticipar problemas, evaluar el impacto de sus estrategias y diseñar políticas más coherentes con las necesidades reales de sus estudiantes. Así, la gestión deja de depender exclusivamente de percepciones fragmentadas y avanza hacia una cultura institucional más informada, colaborativa y orientada a la calidad.

No obstante, el uso de datos educativos también exige una mirada crítica, porque existe el riesgo de reducir al estudiante a un conjunto de métricas, alertas, probabilidades o categorías de riesgo. Cuando esto ocurre, la tecnología deja de ser una herramienta de apoyo y puede transformarse en un mecanismo de vigilancia, clasificación o exclusión, especialmente si las decisiones se toman sin considerar el contexto social, emocional, académico y cultural de quienes aprenden. Por ello, toda propuesta de Learning Analytics debe incorporar principios de privacidad, transparencia, justicia, explicabilidad y responsabilidad

institucional, reconociendo que los datos pueden ayudar a comprender mejor la experiencia estudiantil, pero nunca deben sustituir el juicio docente, la escucha activa ni la dignidad de cada persona.

Este libro parte de una convicción central: una universidad basada en datos solo tiene sentido si conserva su compromiso humano, porque la tecnología, por avanzada que sea, no puede reemplazar la mediación pedagógica ni resolver por sí sola los problemas estructurales de la educación superior. Su verdadero valor aparece cuando se integra con una gestión ética, una cultura de mejora continua, una docencia reflexiva y una visión institucional sensible a la diversidad de trayectorias estudiantiles. Desde esta perspectiva, Learning Analytics no se presenta como una solución mágica, sino como una posibilidad metodológica y estratégica para tomar mejores decisiones, cuidar mejor los procesos formativos y construir instituciones más responsables.

A lo largo de sus capítulos, este libro aborda los fundamentos conceptuales de la educación basada en datos, las aplicaciones de Learning Analytics para mejorar el rendimiento académico, sus aportes a la gestión universitaria y los desafíos éticos que acompañan su implementación. La intención es ofrecer una lectura rigurosa, accesible y útil para docentes, investigadores, gestores académicos y autoridades universitarias interesadas en comprender cómo los datos pueden contribuir a una educación superior más inteligente, inclusiva y pertinente. En última instancia, el propósito no es promover una universidad controlada por algoritmos, sino una universidad capaz de usar la información con criterio, sensibilidad y responsabilidad para mejorar la vida académica de sus estudiantes



The background features a digital dashboard with several data visualization elements: a line graph titled 'Ruta de Aprendizaje' showing an upward trend; a warning icon with the text 'Alerta Temprana' and 'un estudiante se encuentra en necesidad de apoyo'; a pie chart titled 'Comprensión de Contenidos'; a circular progress indicator showing '85%' with the text 'Progreso Individual'; and a bar chart at the bottom right. The student is a young woman with long brown hair, wearing a yellow cardigan and a backpack, sitting at a desk with a laptop and papers.

Capítulo I: Fundamentos de la educación basada en datos en la universidad contemporánea

Fundamentos de la educación basada en datos en la universidad contemporánea

1.1. La universidad ante la cultura de datos

La universidad contemporánea se encuentra ante una transformación que no puede reducirse a la incorporación de plataformas, sistemas de información o modelos predictivos. La cultura de datos implica una forma distinta de comprender la vida académica: observar evidencias, contrastar decisiones, revisar trayectorias y reconocer que los procesos formativos dejan señales que pueden orientar mejores intervenciones. En educación superior, esta cultura adquiere sentido cuando permite fortalecer la enseñanza, acompañar al estudiante y mejorar la gestión institucional sin desplazar el juicio pedagógico ni la responsabilidad ética de quienes toman decisiones. En esa línea, Ifenthaler y Yau (2020) sostienen que la analítica del aprendizaje puede contribuir al éxito estudiantil cuando se orienta a ofrecer retroalimentación y apoyos significativos, no solo a producir reportes.

El tránsito desde decisiones basadas principalmente en intuición hacia decisiones apoyadas en evidencia no significa negar la experiencia docente o directiva. La experiencia sigue siendo necesaria, pero se vuelve más precisa cuando dialoga con información sistemática, oportuna y contextualizada. En este sentido, la educación basada en datos no reemplaza la deliberación académica; la fortalece al permitir que las decisiones sobre enseñanza, evaluación, permanencia y gestión se apoyen en señales verificables. Sin embargo, como advierten Guzmán et al. (2021a), el riesgo de la analítica en educación superior aparece cuando se enfatiza más la dimensión técnica del análisis que la comprensión profunda del aprendizaje.

En este marco conviene diferenciar dato, información, conocimiento y decisión institucional. El dato es un registro primario: una calificación, una asistencia, una entrega tardía, un acceso al aula virtual o una interacción en una actividad. La información surge cuando esos registros se organizan y adquieren significado. El conocimiento aparece cuando la comunidad universitaria interpreta esa información a la luz del currículo, la enseñanza, el contexto del estudiante y los objetivos institucionales. La decisión responsable ocurre cuando ese

conocimiento se transforma en acciones formativas, preventivas o de mejora, sin tratar el indicador como sentencia definitiva; esta distinción es relevante porque la adopción institucional de analítica requiere pasar de la acumulación de registros a la construcción de sentido educativo.

La Figura 1 sintetiza esta lógica como un ecosistema universitario basado en datos, compuesto por estudiantes, docentes, plataformas, gestión académica y calidad institucional. La figura debe representarse con azul profundo para la estructura universitaria, verde para los procesos de aprendizaje e inclusión, dorado suave para ética y calidad, y gris claro para los conectores entre actores y procesos. Esta composición permite visualizar que la analítica no pertenece únicamente al área tecnológica, sino a una red académica donde cada nodo cumple una función formativa. Desde una perspectiva humanocentrada, Alfredo et al. (2024) subrayan que la participación de estudiantes y docentes en el diseño de sistemas analíticos es clave para evitar herramientas desalineadas con las necesidades reales.

Figura 1.

Ecosistema universitario basado en datos



La figura permite comprender que los datos universitarios no son fríos por naturaleza; se vuelven fríos cuando se usan sin interpretación, sin contexto o sin diálogo con quienes participan en la experiencia educativa. En cambio, cuando

se analizan con finalidad pedagógica, pueden hacer visibles dificultades silenciosas, desigualdades de acceso, patrones de participación, necesidades de retroalimentación y oportunidades de acompañamiento. La cultura de datos, por tanto, no debería conducir a una universidad vigilante, sino a una universidad más capaz de mirar, escuchar y actuar con prudencia; esta precaución coincide con Hakimi et al. (2021), quienes señalan que el uso de trazas digitales en educación exige atender privacidad, transparencia, justicia y consecuencias no previstas.

1.1.1. Del dato administrativo al dato pedagógico

Durante mucho tiempo, las universidades han producido datos administrativos para registrar matrícula, asistencia, aprobación, titulación, carga docente, uso de infraestructura y cumplimiento de procesos. Estos datos son necesarios para la operación institucional, pero resultan insuficientes si no se conectan con preguntas pedagógicas. La educación basada en datos comienza a consolidarse cuando el registro administrativo se transforma en evidencia para comprender qué ocurre en la trayectoria formativa, qué apoyos se requieren y qué decisiones pueden mejorar la experiencia universitaria (Ifenthaler y Yau, 2020).

El dato pedagógico no se define solo por su origen, sino por el uso interpretativo que se hace de él. Una nota parcial puede ser un dato evaluativo, pero se vuelve pedagógico cuando ayuda a revisar la comprensión de un tema, la pertinencia de una estrategia didáctica o la necesidad de retroalimentación. Un acceso tardío al aula virtual puede ser un dato de interacción, pero requiere lectura contextual: podría expresar desmotivación, sobrecarga laboral, dificultades de conectividad, problemas de orientación o una planificación poco clara. En esa línea, Saqr et al. (2023) evidencian que la relación entre participación en línea y logro académico varía entre estudiantes y a lo largo del tiempo, por lo que no debe interpretarse desde un único registro aislado.

La Tabla 1 organiza cuatro tipos frecuentes de datos universitarios y sus posibles usos educativos. Su propósito no es cerrar una taxonomía única, sino mostrar que cada fuente de información contiene oportunidades y riesgos interpretativos. En coherencia con la línea gráfica del libro, la tabla debe usar encabezado azul

profundo, resaltados verdes para la utilidad educativa, dorado suave para advertencias éticas y líneas grises para separar campos.

Tabla 1.

Tipos de datos universitarios y usos educativos

Tipo de dato	Fuente habitual	Utilidad educativa	Riesgo interpretativo
Administrativo	Matrícula, asistencia, historial académico, permanencia	Organizar trayectorias, planificar apoyos, identificar necesidades institucionales	Reducir al estudiante a expediente o trámite
Académico	Calificaciones, aprobación, avance curricular, repetición	Analizar progreso, desempeño y consistencia del aprendizaje	Confundir nota con aprendizaje integral
Evaluativo	Rúbricas, retroalimentación, resultados parciales, portafolios	Ajustar enseñanza, mejorar evaluación formativa, orientar recuperación	Usar resultados sin revisar criterios o condiciones
Interacción digital	LMS, foros, entregas, accesos, recursos consultados	Identificar participación, ritmos, patrones de estudio y alertas tempranas	Interpretar clics como compromiso real sin contexto

La tabla evidencia que ningún dato habla por sí solo. Su sentido depende de la pregunta que lo organiza, del marco pedagógico que lo interpreta y de la acción que se deriva de él. Por esta razón, el docente y los equipos académicos no deben ser sustituidos por tableros de control; deben ser fortalecidos con información legible, situada y accionable.

1.1.2. Educación basada en datos: concepto, alcances y límites

La educación basada en datos puede entenderse como un enfoque de gestión pedagógica e institucional que utiliza evidencias sistemáticas para comprender, mejorar y evaluar los procesos educativos. En la universidad, este enfoque articula información académica, administrativa, evaluativa y digital con el

propósito de apoyar el aprendizaje, anticipar riesgos, fortalecer la permanencia, mejorar la docencia y orientar decisiones de calidad. Su fundamento no es acumular datos, sino convertirlos en conocimiento útil para la acción educativa responsable. Esta comprensión se aproxima a lo planteado por Ifenthaler y Yau (2020), quienes vinculan la analítica con retroalimentación, andamiaje y apoyo al éxito académico.

Sus alcances son amplios, pero deben delimitarse con precisión. Puede aportar a la identificación temprana de estudiantes que requieren apoyo, al diseño de retroalimentación más oportuna, al seguimiento de cohortes, a la evaluación de programas, a la revisión de cargas académicas, a la mejora de entornos virtuales y a la planificación de recursos. También puede ayudar a comprender tendencias institucionales, siempre que las decisiones no se basen únicamente en promedios, rankings o modelos automatizados. La literatura sobre abandono universitario muestra que la analítica puede contribuir a la prevención cuando se conecta con acciones de acompañamiento y no con simples clasificaciones de riesgo (De Oliveira et al., 2021).

El primer límite es epistemológico: los datos representan fragmentos de una realidad educativa compleja. Una plataforma puede registrar accesos, entregas o tiempos de conexión, pero no capta por completo comprensión, cansancio, ansiedad, motivación, condiciones familiares, barreras económicas o calidad de la enseñanza. Por ello, la evidencia cuantitativa debe dialogar con información cualitativa, juicio docente, conversación tutorial y análisis curricular. Esta cautela evita convertir el dato en verdad absoluta y permite reconocer la trayectoria del estudiante como una experiencia multidimensional. Saqr et al. (2023) muestran que un único punto temporal de interacción no permite comprender de manera estable el logro académico.

El segundo límite es ético. La disponibilidad de trazas digitales abre oportunidades para mejorar el acompañamiento, pero también riesgos relacionados con privacidad, consentimiento, vigilancia, sesgos, opacidad algorítmica y usos secundarios de la información. Las revisiones recientes sobre ética de datos educativos insisten en que la analítica debe garantizar transparencia, minimización de datos, protección de la autonomía, seguridad y

participación de los actores afectados. Cerratto y McGrath (2021) advierten que la ética de Learning Analytics en educación superior no puede tratarse como un complemento externo, sino como una condición del diseño y uso de los sistemas.

El tercer límite es pedagógico: medir no equivale a mejorar. Los datos solo producen valor cuando se conectan con decisiones formativas: rediseñar una actividad, ajustar una evaluación, abrir tutorías, revisar la carga de lectura, flexibilizar apoyos o mejorar la comunicación académica. Una institución puede tener muchos tableros y, aun así, no acompañar mejor. La educación basada en datos exige cerrar el ciclo entre evidencia, interpretación, intervención y evaluación de resultados. En este punto, Pan et al. (2024) destacan que las intervenciones incorporadas en LMS deben analizarse por su impacto en la enseñanza y el aprendizaje, no solo por su sofisticación técnica.

1.2. Learning Analytics como campo de conocimiento

Learning Analytics constituye un campo interdisciplinar orientado al análisis de datos sobre estudiantes y contextos de aprendizaje para comprender y optimizar los procesos educativos. Su valor en educación superior radica en que conecta tecnologías digitales, ciencias del aprendizaje, estadística, minería de datos, evaluación, diseño instruccional, ética y gestión académica. Esta amplitud explica su crecimiento, pero también obliga a evitar definiciones reducidas que lo presenten solo como predicción de notas o automatización de alertas. García et al. (2024) ubican la analítica del aprendizaje como un campo relevante para estudiar el rendimiento académico desde una perspectiva educativa, aunque reconocen diferencias sustantivas y metodológicas entre las revisiones existentes.

Como campo de conocimiento, Learning Analytics se sitúa en la intersección entre investigación y práctica. Investiga cómo se producen, procesan e interpretan los datos educativos, pero también diseña intervenciones para mejorar enseñanza, aprendizaje y acompañamiento. Las revisiones recientes señalan que las intervenciones basadas en analítica pueden apoyar el éxito académico y la continuidad de los estudios, aunque sus efectos dependen del diseño pedagógico, la calidad de los datos, la oportunidad de la intervención y el compromiso de los actores institucionales. Esta condición ha sido resaltada por

Ifenthaler y Yau (2020), quienes enfatizan el papel de la retroalimentación y los andamiajes oportunos.

La finalidad de Learning Analytics no debe confundirse con vigilancia. Su orientación académica legítima es comprender mejor cómo aprenden los estudiantes, qué condiciones institucionales facilitan o dificultan su avance y qué apoyos pueden activarse sin estigmatizar. La Figura 2 presenta sus componentes conceptuales: aprendizaje, datos, análisis, intervención, ética y gestión. Su diseño radial muestra que la analítica pierde sentido si cualquiera de estos componentes se aísla del resto. Esta lectura coincide con Alfredo et al. (2024), quienes proponen enfoques humanocentrados para equilibrar automatización, control humano, seguridad y confianza.

Figura 2.

Componentes conceptuales de Learning Analytics



La figura permite sostener una idea central: Learning Analytics no es una herramienta aislada, sino un ciclo sociotécnico. El componente técnico procesa datos; el componente pedagógico interpreta su significado; el componente ético define límites; y el componente institucional crea condiciones para actuar. Cuando estos elementos se articulan, la analítica puede apoyar la enseñanza y la gestión. Cuando se separan, puede convertirse en clasificación superficial, presión administrativa o automatización de decisiones sin responsabilidad

humana. Hakimi et al. (2021) recuerdan que el uso de trazas digitales en educación exige examinar consecuencias éticas, contextuales e institucionales.

La evidencia acumulada sugiere resultados promisorios, aunque no uniformes. Algunas revisiones identifican aportes en retroalimentación, diseño de intervenciones, participación y apoyo al estudio; otras advierten que el impacto sobre logro académico depende de diseños rigurosos y de evaluaciones más sólidas. Esta tensión es saludable para el campo, porque impide presentar la analítica como solución automática. En una universidad responsable, los datos no prometen milagros; ofrecen mejores preguntas y condiciones para intervenir con mayor oportunidad. En esta línea, Banihashem et al. (2022) muestran que la analítica puede fortalecer prácticas de retroalimentación, pero su efectividad depende de cómo se integra al diseño pedagógico.

Por ello, Learning Analytics debe pensarse como una práctica institucional escalable, pero no despersonalizada. La escala permite observar cohortes, programas y tendencias; la sensibilidad pedagógica impide olvidar a la persona que está detrás de cada señal. Las investigaciones sobre adopción destacan la importancia de estrategias institucionales, participación de docentes y estudiantes, políticas claras y apropiación gradual. La analítica no se instala solo con software; se construye con cultura académica, capacidades humanas y confianza.

1.2.1. Evolución de Learning Analytics en educación superior

La evolución de Learning Analytics en educación superior puede leerse como un aprendizaje progresivo del propio sistema universitario. En una primera etapa, predominó la analítica descriptiva: reportes de acceso, calificaciones, asistencia, aprobación y actividad en plataformas. Estos registros permitieron reconocer patrones generales, pero su utilidad era limitada cuando se quedaban en informes retrospectivos. El desafío fue pasar del dato que describe lo ocurrido al dato que ayuda a comprender por qué ocurrió y qué puede hacerse. Guzmán et al. (2021b) advierten que este paso es indispensable para que el campo no quede atrapado en una abundancia de análisis con poca comprensión del aprendizaje.

En una segunda etapa, el campo avanzó hacia modelos predictivos y sistemas de alerta temprana. El interés se concentró en anticipar bajo rendimiento, abandono, desconexión o riesgo académico mediante datos de LMS, historial académico y desempeño parcial. Estos avances ampliaron las posibilidades de acompañamiento, pero también abrieron debates sobre sesgos, explicabilidad y oportunidad de la intervención. Predecir no basta: la pregunta clave es qué apoyo institucional se activa, con qué criterios y con qué respeto por la autonomía del estudiante. Namoun y Alshantiri (2020) muestran que las técnicas de minería de datos y analítica pueden predecir desempeño, aunque requieren interpretación educativa cuidadosa.

La Tabla 2 resume esta evolución desde reportes descriptivos hasta aproximaciones prescriptivas y humanocentradas. Su lectura debe evitar la idea de progreso lineal inevitable; las etapas conviven y pueden combinarse según la madurez institucional. La tabla debe usar azul profundo para las etapas, verde para el aporte educativo, dorado suave para advertencias de calidad y ética, y gris claro para relaciones de continuidad.

Tabla 2.

Evolución de Learning Analytics

Etapas	Foco analítico	Tecnología asociada	Aporte educativo
Descriptiva	Qué ocurrió	Reportes, tableros básicos, indicadores	Visibilizar actividad académica y patrones generales
Diagnóstica	Por qué pudo ocurrir	Cruce de datos, segmentación, análisis comparativo	Comprender causas probables y condiciones de aprendizaje
Predictiva	Qué podría ocurrir	Modelos estadísticos, machine learning, alertas tempranas	Anticipar riesgo y activar apoyo oportuno
Prescriptiva	Qué acción conviene realizar	Recomendadores, reglas de intervención, analítica adaptativa	Orientar decisiones pedagógicas y tutoriales

Humanocentrada	Cómo intervenir con sentido ético	Diseño participativo, explicabilidad, gobernanza de datos	Proteger autonomía, confianza y calidad formativa
----------------	---	---	---

La tabla muestra que la madurez de Learning Analytics no consiste en usar técnicas más complejas, sino en tomar mejores decisiones educativas. Un modelo predictivo puede ser menos valioso que un tablero simple si no activa apoyo real. Del mismo modo, una recomendación automatizada puede ser riesgosa si no permite revisión humana. La evolución deseable del campo apunta hacia sistemas explicables, participativos y conectados con intervenciones pedagógicas evaluables. Alfredo et al. (2024) sostienen que los sistemas de analítica e inteligencia artificial educativa necesitan mayor participación de usuarios finales, especialmente estudiantes y docentes, para fortalecer seguridad, control humano y confianza.

1.2.2. Diferencias entre Learning Analytics, Educational Data Mining y Academic Analytics

Learning Analytics, Educational Data Mining y Academic Analytics comparten el interés por usar datos en educación, pero difieren en escala, propósito, usuarios y tipo de decisión. La distinción no debe plantearse como separación rígida, porque los campos se solapan y colaboran. Sin embargo, diferenciarlos ayuda a evitar confusiones: no todo modelo estadístico aplicado a educación es Learning Analytics, ni toda gestión institucional basada en indicadores tiene finalidad pedagógica inmediata. Lemay et al. (2021) muestran, mediante modelado temático, que Learning Analytics y Educational Data Mining comparten zonas de interés, aunque desarrollan énfasis y comunidades parcialmente diferenciadas.

Learning Analytics se centra en comprender y mejorar el aprendizaje y sus entornos. Su unidad de análisis puede ser el estudiante, el grupo, la actividad, el curso o el programa, pero su orientación principal es pedagógica. Por ello, los usuarios esperados no son únicamente analistas o directivos, sino docentes, tutores, coordinadores académicos y estudiantes. En este campo, el valor del dato se mide por su capacidad para apoyar comprensión, retroalimentación, intervención y mejora de la experiencia formativa. Como señalan Pan et al.

(2024), las intervenciones analíticas incorporadas a LMS deben evaluarse por su aporte a prácticas de enseñanza y aprendizaje.

Educational Data Mining se enfoca en desarrollar y aplicar métodos computacionales para descubrir patrones en grandes conjuntos de datos educativos. Su fortaleza está en técnicas como clasificación, agrupamiento, reglas de asociación, minería de secuencias, predicción y modelado. Puede contribuir de manera importante a Learning Analytics, pero no siempre incorpora de forma explícita la dimensión pedagógica, ética o institucional de la intervención. Por eso, sus hallazgos requieren traducción educativa antes de convertirse en decisiones sobre enseñanza o acompañamiento. Esta diferencia metodológica y de propósito ha sido discutida por Lemay et al. (2021).

Academic Analytics opera en una escala más institucional y estratégica. Analiza información sobre programas, cohortes, retención, eficiencia terminal, recursos, desempeño institucional, planificación académica y calidad. Su usuario principal suele ser la gestión universitaria, aunque sus resultados pueden incidir en decisiones pedagógicas. La Tabla 3 compara estos campos y muestra ejemplos universitarios de uso. Esta distinción permite ubicar cada enfoque sin jerarquizarlos artificialmente.

Tabla 3.

Comparación entre campos analíticos

Campo	Unidad de análisis	Propósito	Usuario principal	Ejemplo universitario
Learning Analytics	Estudiante, actividad, curso, programa	Comprender y mejorar aprendizaje, evaluación y acompañamiento	Docentes, tutores, estudiantes, coordinadores	Identificar necesidad de retroalimentación en una asignatura
Educational Data Mining	Grandes conjuntos de datos educativos	Descubrir patrones, clasificar, predecir, modelar	Investigadores, científicos de datos, equipos técnicos	Crear un modelo para anticipar desempeño en LMS

Academic Analytics	Cohortes, programas, facultades, institución	Mejorar planificación, calidad, permanencia y gestión	Directivos, planificación, aseguramiento de la calidad	Analizar retención por carrera y rediseñar apoyos institucionales
-----------------------	---	---	---	--

La tabla ayuda a sostener una decisión conceptual para este libro: Learning Analytics será entendido como puente entre evidencia, aprendizaje y gestión responsable. No se lo reducirá a minería de datos, porque requiere interpretación pedagógica; tampoco se lo limitará a gestión institucional, porque su núcleo es la mejora del aprendizaje. Su potencia está en conectar los tres campos sin perder el sentido educativo de las decisiones. Esta posición dialoga con García et al. (2026), quienes proponen mirar la relación entre analítica y rendimiento académico desde una perspectiva educativa, no solo técnica.

1.3. Rendimiento académico como construcción multidimensional

El rendimiento académico universitario debe comprenderse como una construcción multidimensional, no como un sinónimo de calificación final. Las notas aportan información relevante, pero no agotan el aprendizaje ni explican por sí mismas la trayectoria estudiantil. En educación superior, el rendimiento integra progreso, participación, permanencia, logro de resultados de aprendizaje, autorregulación, evaluación, bienestar, condiciones institucionales y oportunidades reales de apoyo. Esta mirada evita culpabilizar al estudiante y desplaza el análisis hacia una comprensión más justa de las trayectorias. García et al. (2026) destacan que el estudio del rendimiento mediante analítica requiere una perspectiva educativa capaz de reconocer su complejidad.

Reducir el rendimiento a resultados numéricos puede conducir a decisiones empobrecidas. Un estudiante con baja calificación puede estar enfrentando dificultades conceptuales, brechas previas, problemas económicos, sobrecarga laboral, barreras tecnológicas, escasa retroalimentación o una evaluación poco alineada con los objetivos de aprendizaje. La analítica puede ayudar a diferenciar estas situaciones, pero solo si se interpreta junto con evidencia pedagógica y conocimiento contextual. El rendimiento, por tanto, no debe leerse como atributo

individual aislado, sino como resultado de relaciones entre estudiante, aula, currículo e institución. Esta idea se refuerza en el trabajo de Saqr et al. (2023), donde la asociación entre participación y logro varía según perfiles y momentos del proceso formativo.

La investigación longitudinal sobre participación y logro muestra que la relación entre compromiso digital y rendimiento no es simple ni estable. La participación en plataformas puede ofrecer señales útiles, pero un único punto temporal no siempre permite anticipar desempeño futuro con suficiente fiabilidad. Los estudios de trayectorias advierten que el compromiso cambia, se estabiliza, fluctúa o se debilita según condiciones académicas y personales. Esta evidencia obliga a usar indicadores con prudencia y a evitar etiquetas tempranas que limiten expectativas. En particular, Saqr et al. (2023) advierten que el compromiso en línea en un único momento no es un indicador consistente de alto logro a lo largo de todo un programa.

Desde esta perspectiva, el bajo rendimiento no debe interpretarse como falla moral, falta de esfuerzo o déficit individual. Puede expresar una trayectoria que requiere mediación, una enseñanza que necesita ajuste, una evaluación que demanda retroalimentación más clara o una institución que debe mejorar sus apoyos. Learning Analytics aporta cuando permite identificar señales de necesidad y activar acompañamiento oportuno, no cuando produce clasificaciones que marcan al estudiante como problema. La universidad basada en datos debe sostener una ética de corresponsabilidad. En esta línea, De Oliveira et al. (2021) vinculan la prevención del abandono con acciones institucionales derivadas del análisis, no con la simple detección de riesgo.

La Figura 3 representa el rendimiento académico como un sistema de capas concéntricas: estudiante, aula, curso, programa e institución. El centro no se presenta como lugar de culpa, sino como punto de articulación entre experiencia personal y condiciones formativas. La línea gráfica debe mantener azul profundo para la institución, verde para aprendizaje e inclusión, dorado suave para calidad y evaluación, y gris claro para relaciones entre niveles. Esta lectura sistémica es coherente con la literatura reciente que ubica el rendimiento como fenómeno

dependiente de múltiples condiciones académicas, institucionales y personales (García-García et al., 2026).

Figura 3.

Dimensiones del rendimiento académico universitario



La figura permite comprender que cualquier indicador de rendimiento debe ubicarse en un entramado más amplio. Una alerta de riesgo no debería conducir a sanción, sino a pregunta pedagógica: qué está pasando, qué evidencia adicional se necesita, qué apoyo es pertinente y cómo se evaluará la mejora. Esta mirada transforma la analítica en un instrumento de acompañamiento académico y no en una tecnología de clasificación. Hakimi et al. (2021) advierten que el uso de datos educativos debe considerar no solo posibilidades técnicas, sino también efectos éticos y sociales sobre los sujetos involucrados.

1.3.1. Indicadores académicos, trayectorias y señales tempranas

Los indicadores académicos son señales construidas para interpretar trayectorias, no diagnósticos cerrados sobre las personas. Pueden incluir asistencia, aprobación, reprobación, calificaciones parciales, entregas, participación en actividades, interacción con recursos, avance curricular,

permanencia y solicitudes de apoyo. Su utilidad depende de la calidad del dato, la pertinencia del indicador y la capacidad institucional para actuar. Un indicador sin intervención puede producir preocupación administrativa, pero no mejora educativa. Riestra-González et al. (2021) muestran que los datos masivos de LMS pueden apoyar predicciones tempranas, aunque su valor educativo depende de cómo se utilicen para orientar acciones.

Las señales tempranas son especialmente relevantes porque permiten intervenir antes de que una dificultad se consolide. Los modelos de predicción basados en registros de LMS han mostrado capacidad para anticipar desempeño en distintos momentos del curso, pero su uso debe ser cuidadoso. No toda baja interacción significa abandono, ni toda entrega tardía implica desinterés. La señal temprana debe abrir una conversación académica, no cerrar una interpretación. En este sentido, Soffer y Cohen (2024) muestran que los estudiantes pueden valorar usos pedagógicos de la analítica, pero también expresan preocupaciones sobre privacidad, transparencia y protección de datos.

La Tabla 4 propone indicadores de alerta académica con posibles interpretaciones y acciones de apoyo. La columna central evita presentar la señal como causa única; la última columna enfatiza respuestas pedagógicas, tutoriales o institucionales. Su diseño debe usar verde en acciones de apoyo, dorado suave en posibles interpretaciones y azul profundo en el encabezado institucional.

Tabla 4.

Indicadores de alerta académica

Indicador	Señal	Posible interpretación	Acción de apoyo
Entregas incompletas	Dos o más actividades no presentadas	Dificultad de comprensión, tiempo, conectividad o planificación	Tutoría breve, recordatorio formativo, revisión de consignas
Baja participación en LMS	Pocos accesos o interacción irregular	Desconexión, sobrecarga, baja claridad del aula virtual	Contacto tutorial, orientación de navegación, ajuste de recursos

Descenso en evaluaciones parciales	Caída sostenida de resultados	Brecha conceptual o evaluación no comprendida	Retroalimentación específica, actividad de recuperación, apoyo entre pares
Inasistencia recurrente	Ausencias repetidas	Problemas personales, laborales, salud, transporte o desmotivación	Derivación a bienestar, flexibilización razonable, seguimiento académico
Riesgo de abandono	Combinación de señales académicas y administrativas	Trayectoria frágil o falta de apoyo oportuno	Plan de acompañamiento, revisión de carga, coordinación institucional

La tabla muestra que una misma señal admite varias explicaciones. Esta pluralidad obliga a combinar datos con escucha institucional. La analítica no debe reemplazar la tutoría ni el criterio docente; debe ayudar a priorizar, focalizar y documentar apoyos. Cuando una universidad usa alertas tempranas con esta lógica, el estudiante deja de ser observado como “caso de riesgo” y pasa a ser acompañado como sujeto de derecho educativo. Esta orientación es coherente con Cerratto y McGrath (2021), quienes ubican la ética como dimensión central de la analítica en educación superior.

El uso de indicadores también requiere protocolos claros. La institución debe definir quién accede a la información, con qué finalidad, durante cuánto tiempo, bajo qué medidas de protección y cómo se comunica al estudiante. Los estudios sobre privacidad muestran que muchos estudiantes aceptan usos pedagógicos de los datos cuando perciben transparencia, confianza y beneficios claros, pero también demandan control y protección. Por ello, una alerta ética debe ser explicable, revisable y orientada a apoyo. Soffer y Cohen (2024) confirman que la confianza, la conciencia sobre protección de datos y la percepción de beneficio pedagógico influyen en la disposición estudiantil a compartir información.

1.3.2. Aporte de Learning Analytics a la literatura en educación superior

El aporte de Learning Analytics a la literatura en educación superior se encuentra en su capacidad para articular tres niveles que con frecuencia se estudian por

separado: aprendizaje, rendimiento y gestión universitaria. Al conectar datos de interacción, evaluación, trayectoria y contexto institucional, el campo permite formular preguntas más integradoras sobre cómo aprenden los estudiantes, qué apoyos necesitan y cómo la universidad puede mejorar sus decisiones. Esta integración constituye una contribución científica y práctica, siempre que se sostenga en evidencia, ética y sensibilidad pedagógica. García et al. (2026) destacan precisamente la necesidad de estudiar el rendimiento académico mediante Learning Analytics desde una perspectiva educativa.

Este libro se inscribe en esa línea, pero asume una posición crítica: los datos no son una solución por sí mismos. La literatura reciente muestra avances importantes en intervenciones, tableros, predicción, retroalimentación y apoyo al estudio, pero también identifica límites metodológicos, resultados heterogéneos y necesidad de evaluaciones más rigurosas. Por ello, el enfoque propuesto no celebra la analítica como moda tecnológica; la entiende como una práctica académica que debe demostrar pertinencia, impacto y legitimidad institucional. Esta cautela se relaciona con Kaliisa et al. (2024), quienes advierten que los tableros de analítica no siempre muestran efectos sólidos sobre logro, motivación o participación.

Una contribución relevante consiste en desplazar la conversación desde la predicción del rendimiento hacia la mejora de las condiciones de aprendizaje. Predecir quién podría tener dificultades es útil solo si permite intervenir de manera justa, oportuna y pedagógicamente fundada. La pregunta central no debería ser “quién fallará”, sino qué necesita la institución para acompañar mejor, qué ajustes requiere la enseñanza y qué barreras pueden removerse para sostener la permanencia y el logro formativo. Ifenthaler y Yau (2020) muestran que la analítica tiene mayor sentido cuando se vincula con apoyos, retroalimentación y andamiajes orientados al éxito académico.

Otra contribución es integrar Learning Analytics con gobernanza universitaria responsable. La toma de decisiones basada en datos exige políticas de privacidad, criterios de calidad, transparencia algorítmica, participación de docentes y estudiantes, formación institucional y evaluación de efectos. La literatura sobre enfoques humanocentrados advierte que excluir a los actores

educativos del diseño puede generar desconfianza y herramientas mal alineadas con las necesidades reales. Una universidad basada en datos debe diseñar con las personas, no solo para las personas. Esta perspectiva coincide con Alfredo et al. (2024), quienes recomiendan involucrar activamente a usuarios finales en el diseño de sistemas de analítica e inteligencia artificial educativa.

En síntesis, los fundamentos de la educación basada en datos en la universidad contemporánea descansan en una idea central: los datos tienen valor educativo cuando ayudan a comprender mejor para actuar mejor. Learning Analytics puede mejorar rendimiento, evaluación, acompañamiento, permanencia y gestión, pero solo si se orienta por principios pedagógicos y éticos. La universidad que aprende de sus datos no vigila más; acompaña mejor, decide con mayor responsabilidad y reconoce que detrás de cada indicador existe una trayectoria humana que merece ser comprendida. Esta conclusión dialoga con Hakimi et al. (2021), quienes recuerdan que el uso de datos digitales en educación debe evaluarse por sus implicaciones éticas, sociales y formativas.



The background of the page features a series of semi-transparent educational data dashboards. The top-left dashboard, titled 'Ruta de Aprendizaje' (Learning Path), displays a line graph with two upward-trending lines. The top-right dashboard, titled 'Alerta Temprana' (Early Warning), shows a yellow warning triangle icon and a person icon, with text indicating a student is in need of support. The middle-left dashboard, titled 'Comprensión de Contenidos' (Content Understanding), includes a pie chart. The middle-right dashboard, titled 'Progreso Individual' (Individual Progress), shows a circular progress indicator at 85% and a bar chart. The student in the foreground is a young woman with long brown hair, wearing a yellow cardigan over a white shirt and a blue backpack. She is sitting at a wooden desk, looking at a tablet computer. A laptop is open to her right, and a notebook with a pen lies in front of her. The overall scene is set in a modern, brightly lit environment with a window showing a cityscape and a tree.

Capítulo II: Datos, plataformas e inteligencia analítica para comprender el aprendizaje universitario

Datos, plataformas e inteligencia analítica para comprender el aprendizaje universitario

2.1. Fuentes de datos en los ecosistemas universitarios digitales

La universidad contemporánea produce datos de manera continua, aunque no siempre los reconoce como parte de un ecosistema institucional de aprendizaje. En un curso mediado por plataformas, los accesos al aula virtual, las entregas de tareas, las calificaciones parciales, la participación en foros, el uso de bibliotecas digitales, las tutorías, la asistencia y las encuestas de experiencia estudiantil conforman señales dispersas sobre cómo se estudia, se enseña y se gestiona. Desde la perspectiva de Romero y Ventura (2020), la analítica del aprendizaje se ubica en un campo amplio donde convergen minería de datos educativos, analítica institucional y ciencia de datos educativa, siempre con el propósito de comprender y optimizar procesos de formación. No se trata, entonces, de acumular registros, sino de convertirlos en preguntas útiles para mejorar el acompañamiento académico.

En educación superior, las fuentes de datos suelen organizarse alrededor de tres grandes espacios: los entornos digitales de aprendizaje, los sistemas académicos-administrativos y los espacios de interacción pedagógica. Los LMS registran trazas de actividad; los sistemas académicos almacenan matrícula, historial, avance curricular y rendimiento; las bibliotecas digitales permiten observar búsquedas, préstamos y acceso a recursos; y las tutorías o servicios de bienestar aportan información cualitativa sobre necesidades de apoyo. Afzaal y Nouri (2024) muestran que el software de Learning Analytics en educación superior suele orientarse a identificar estudiantes en riesgo, apoyar autorregulación y fortalecer aprendizaje colaborativo, lo cual exige mirar las plataformas como parte de un sistema más amplio y no como repositorios aislados.

La dispersión de datos es uno de los problemas más sensibles para la gestión universitaria. Una carrera puede tener reportes de aprobación, un LMS puede mostrar baja participación, una biblioteca puede evidenciar poco uso de literatura científica y el área de bienestar puede registrar dificultades socioemocionales;


sin embargo, si esas señales no dialogan, la institución reacciona tarde. Dixon y Howe (2025) advierten, desde casos de educación superior, que la infraestructura y la precisión de los datos son condiciones relevantes para que la analítica ayude a comprender las prácticas de aprendizaje y ajustar currículo o contenidos. La información, por sí misma, no acompaña a nadie; acompaña cuando se integra, se interpreta y se convierte en decisión pedagógica.

La calidad de las fuentes también requiere cautela. Un registro de acceso no siempre significa aprendizaje profundo, una calificación baja no siempre expresa falta de esfuerzo y una ausencia reiterada puede estar relacionada con conectividad, trabajo, salud, responsabilidades familiares o dificultades de adaptación universitaria. Ifenthaler y Yau (2020) recuerdan que el éxito académico en educación superior no puede comprenderse únicamente desde métricas aisladas, pues la analítica necesita apoyarse en andamiajes, retroalimentación y sistemas de apoyo oportunos. La lectura humanizada de los datos evita transformar una señal académica en una etiqueta sobre el estudiante.

La Figura 4 sintetiza este ecosistema de datos desde una mirada institucional. Su propósito no es presentar una arquitectura técnica cerrada, sino mostrar que las fuentes universitarias solo adquieren valor cuando se conectan con decisiones sobre aprendizaje, evaluación, permanencia, tutoría y calidad académica. En esta lógica, los datos no sustituyen la conversación docente ni la deliberación institucional; más bien, ayudan a que ambas ocurran con mayor oportunidad y evidencia. Lang et al. (2022) sitúan Learning Analytics como un campo maduro que combina métodos, medición, modelos predictivos, políticas y ética, lo cual confirma que el análisis de datos universitarios exige una visión integral.

Figura 4.

Mapa de fuentes de datos universitarios



2.1.1. LMS, interacción digital y trazas de aprendizaje

El LMS constituye una de las fuentes más visibles para Learning Analytics porque registra huellas de interacción que antes quedaban fuera de la mirada docente. Accesos al curso, visualización de recursos, participación en foros, envío de tareas, tiempos de conexión, intentos de cuestionarios y recepción de retroalimentación conforman datos de proceso. Pan et al. (2024) revisan intervenciones de analítica incorporadas en LMS y muestran que estas pueden aportar evidencia para diseñar apoyos, orientar actividades y analizar efectos de intervenciones instruccionales. La clave está en no confundir traza con aprendizaje, sino en usarla como señal inicial para preguntar mejor.

Las trazas digitales permiten observar ritmos de trabajo, momentos de mayor actividad, recursos poco utilizados y puntos de abandono dentro de una secuencia didáctica. Por ejemplo, si muchos estudiantes abren una lectura pero no completan la actividad posterior, el problema podría estar en la complejidad del recurso, en la claridad de la consigna, en la carga de trabajo o en el tipo de

retroalimentación disponible. Pan et al. (2024) revisan intervenciones de analítica incorporadas en LMS y muestran que estas pueden aportar evidencia para diseñar apoyos, orientar actividades y analizar efectos de intervenciones instruccionales. La clave está en no confundir traza con aprendizaje, sino en usarla como señal inicial para preguntar mejor.

La baja conexión no debe ser leída de manera automática como desinterés estudiantil. En educación superior, especialmente en contextos de desigualdad digital, un estudiante puede participar poco en la plataforma por limitaciones de conectividad, trabajo remunerado, horarios fragmentados, responsabilidades de cuidado o dificultades para comprender la navegación del aula virtual. Bergdahl et al. (2024) muestran que el compromiso estudiantil en Learning Analytics es un constructo complejo, asociado a dimensiones conductuales, cognitivas, afectivas y contextuales. Por eso, la interpretación pedagógica debe preceder a cualquier juicio sobre el rendimiento.

Desde el diseño instruccional, las trazas del LMS pueden orientar mejoras muy concretas: reducir ambigüedad en instrucciones, reorganizar recursos, diversificar actividades, distribuir mejor evaluaciones, activar recordatorios formativos o ajustar retroalimentación. Al-Zahrani y Alasmari (2023) evidencian que los indicadores de acceso, interacción, uso de contenidos y evaluación pueden apoyar la personalización instruccional y el compromiso en educación superior en línea. Sin embargo, esta personalización no debería entenderse como automatización fría, sino como rediseño pedagógico sensible a las necesidades reales de los estudiantes.

La Tabla 5 propone una lectura pedagógica de algunas trazas habituales en LMS. La intención es mostrar que cada dato admite más de una interpretación y que, antes de intervenir, conviene contrastar la señal con el diseño del curso, la voz estudiantil y la evidencia evaluativa. Así, Learning Analytics se convierte en una herramienta de mejora didáctica y no en un sistema de vigilancia del comportamiento digital. Esta cautela coincide con el enfoque human-centered defendido por Alfredo et al. (2024), quienes recomiendan involucrar a estudiantes y docentes en el diseño y despliegue de sistemas analíticos.

Tabla 5.

Trazas digitales y posibles lecturas pedagógicas

Traza LMS	Lectura inicial	Cautela interpretativa	Decisión didáctica posible
Bajo acceso semanal	Riesgo de desconexión	Puede deberse a conectividad, trabajo o navegación poco clara	Contacto tutorial, guía breve de uso, revisión de carga
Mucho tiempo en un recurso	Interés o dificultad	Puede indicar confusión, lectura compleja o recurso extenso	Fragmentar contenido, añadir ejemplo, ofrecer síntesis
Pocas participaciones en foro	Baja interacción	Puede haber inseguridad, consigna débil o poca utilidad percibida	Rediseñar pregunta, usar roles, retroalimentar intervenciones
Tareas entregadas tarde	Problemas de planificación	Puede reflejar sobrecarga, calendario acumulado o barreras externas	Reorganizar cronograma, activar recordatorios, tutoría preventiva
Muchos intentos en cuestionario	Persistencia o dificultad conceptual	El error puede estar en contenidos previos o ítems ambiguos	Retroalimentación específica, recurso remedial, revisión de ítems
No visualiza retroalimentación	Desaprovechamiento formativo	Puede no saber dónde verla o no percibir utilidad	Enseñar uso de feedback, enviar resumen, cerrar ciclo evaluativo

2.1.2. Integración de datos académicos, administrativos y pedagógicos

La integración de datos académicos, administrativos y pedagógicos es una condición para que Learning Analytics aporte decisiones confiables. Interoperar no significa simplemente unir bases de datos, sino establecer criterios comunes

de calidad, significado, periodicidad, acceso, responsabilidad y uso. Una universidad puede tener buenos registros en matrícula, LMS, biblioteca y evaluación; aun así, si cada sistema usa categorías distintas, códigos inconsistentes o calendarios desarticulados, la analítica resultante será frágil. Saqr y López-Pernas (2024) subrayan la importancia de métodos rigurosos de limpieza, organización, modelado y visualización para que los datos educativos se conviertan en análisis válidos y reproducibles.

La integración también es una tarea colaborativa entre unidades institucionales. Tecnología debe asegurar infraestructura e interoperabilidad; docencia debe definir qué indicadores tienen sentido pedagógico; bienestar debe aportar lectura contextual; coordinación académica debe transformar hallazgos en acciones; y gobierno universitario debe establecer límites éticos. Lang et al. (2022), en el capítulo sobre políticas de Learning Analytics del *Handbook of Learning Analytics*, destacan que las instituciones necesitan alinear la analítica con estrategias, objetivos, gobernanza y participación de actores. Sin esa articulación, los reportes pueden multiplicarse sin producir mejora real.

La calidad de datos debe pensarse como una forma de justicia educativa. Si los registros están incompletos, desactualizados o sesgados hacia quienes interactúan más con plataformas digitales, las decisiones pueden invisibilizar a estudiantes con menor conectividad, con trayectorias discontinuas o con necesidades de apoyo no capturadas por el sistema. Cerratto y McGrath (2021) muestran que la ética de Learning Analytics en educación superior se concentra en temas como privacidad, transparencia y consentimiento informado, pero también exige revisar cómo los datos configuran relaciones de poder. Integrar datos sin gobernanza puede ser eficiente, pero no necesariamente responsable.

Una integración institucional responsable permite pasar de diagnósticos tardíos a respuestas oportunas. Por ejemplo, una señal combinada de bajo acceso al LMS, descenso de calificaciones parciales y ausencia de tutoría puede activar una conversación académica, no una sanción. La finalidad es construir rutas de acompañamiento, ajustar prácticas de enseñanza, orientar recursos de bienestar y mejorar la planificación de asignaturas críticas. Drăgoi et al. (2026) encuentran que la confianza institucional, la transparencia, el control y la percepción de

beneficios influyen en la disposición estudiantil a permitir usos de datos educativos; por tanto, integrar datos exige también sostener legitimidad ante quienes los generan.

2.2. Niveles de analítica: descriptiva, diagnóstica, predictiva y prescriptiva

La inteligencia analítica universitaria puede comprenderse como una progresión de niveles: descriptivo, diagnóstico, predictivo y prescriptivo. La analítica descriptiva responde qué está ocurriendo; la diagnóstica pregunta por qué podría estar ocurriendo; la predictiva estima qué podría pasar si las condiciones se mantienen; y la prescriptiva sugiere acciones posibles. Esta escalera no debe entenderse como jerarquía tecnocrática, sino como madurez interpretativa. Romero y Ventura (2020) ubican estos procesos dentro de un campo que combina métodos de análisis, minería, modelado y visualización para atender problemas educativos.

La analítica descriptiva es el punto de partida porque organiza datos existentes en reportes comprensibles. Tasas de aprobación, promedios por asignatura, acceso a recursos, entrega de actividades, asistencia y participación permiten observar patrones básicos. Sin embargo, describir no equivale a comprender: una asignatura con alta reprobación puede evidenciar dificultades conceptuales, evaluación mal alineada, sobrecarga, falta de prerrequisitos o condiciones externas al aula. García et al. (2026) advierten que las revisiones sobre Learning Analytics y rendimiento académico en educación superior han prestado atención limitada a contextos instruccionales, fines pedagógicos, dominios disciplinares y teorías educativas.

La analítica diagnóstica profundiza la descripción mediante cruces, comparaciones y búsqueda de factores asociados. Puede analizar cohortes, modalidades, asignaturas críticas, secuencias de evaluación, uso de recursos o momentos de desconexión dentro del semestre. Su valor reside en abrir hipótesis pedagógicas, no en cerrar explicaciones únicas. Ifenthaler y Yau (2020) señalan que la evidencia sobre Learning Analytics para apoyar el éxito universitario requiere fortalecer el vínculo entre indicadores, teorías de aprendizaje e

intervenciones. Por eso, una universidad analítica no solo pregunta cuántos reprobaron, sino qué apoyos faltaron y qué condiciones se pueden mejorar.

La analítica predictiva incorpora modelos estadísticos o de aprendizaje automático para anticipar probabilidades de desempeño, abandono o necesidad de apoyo. Riestra-González et al. (2021) muestran que los registros masivos de LMS pueden utilizarse para predicción temprana del rendimiento en cursos universitarios, incluso en distintos momentos del curso. No obstante, la predicción debe leerse con prudencia: un modelo puede señalar riesgo, pero no conoce por sí solo la historia del estudiante ni las barreras que enfrenta. La predicción responsable abre una oportunidad de acompañamiento, no una sentencia anticipada.

La analítica prescriptiva es la más delicada porque pasa de estimar escenarios a recomendar acciones. Puede sugerir tutorías, recursos remediales, rediseño de actividades, mensajes de orientación, ajustes de evaluación o derivación a servicios de apoyo. Fazil et al. (2024) proponen un modelo profundo para predecir desempeño usando datos de participación, pero este tipo de avance técnico necesita interpretabilidad, validación contextual y supervisión humana. Un algoritmo no debe decidir por la universidad; debe alimentar una deliberación profesional mejor informada.

La Figura 5 presenta la escalera de madurez analítica universitaria. El ascenso entre niveles no implica reemplazar la experiencia docente, sino ampliar la capacidad institucional para detectar señales, interpretarlas, anticiparse y actuar con sentido educativo. La madurez analítica se expresa menos en la sofisticación del tablero y más en la calidad de las decisiones que genera. Como advierten Alfredo et al. (2024), los sistemas de analítica e IA deben diseñarse con participación de actores, equilibrio entre control humano y automatización, seguridad, fiabilidad y confianza.

Figura 5.

Escalera de madurez analítica universitaria



2.2.1. Analítica descriptiva y diagnóstica del desempeño académico

La analítica descriptiva del desempeño académico permite construir una primera imagen de lo que ocurre en cursos, carreras y cohortes. Reportes de aprobación, promedios, distribución de calificaciones, asistencia, avance curricular, participación en LMS y cumplimiento de actividades ayudan a detectar puntos críticos. Molla et al. (2025) plantean que las aplicaciones de Learning Analytics al rendimiento académico en educación superior requieren protocolos sistemáticos para revisar evidencia y evitar lecturas fragmentarias. Así, el dato descriptivo se convierte en punto de partida para una investigación pedagógica institucional.

La analítica diagnóstica añade profundidad porque cruza variables y explora posibles relaciones. Una universidad puede comparar rendimiento por modalidad, momento de ingreso, asignatura previa, tipo de evaluación, uso de recursos, interacción con retroalimentación o participación en tutorías. No se

busca encontrar culpables, sino reconocer condiciones que favorecen o dificultan el aprendizaje. Khalil et al. (2023), citados en literatura reciente sobre el campo, insisten en que el uso de teoría del aprendizaje es clave para que la analítica no se reduzca a correlaciones operativas sin sentido educativo.

El diagnóstico exige formular preguntas evaluativas pertinentes. No basta con saber qué asignatura tiene más reprobación; conviene preguntar si los resultados se concentran en una unidad, si la evaluación mide los resultados de aprendizaje previstos, si las instrucciones fueron claras, si existieron oportunidades de retroalimentación y si los estudiantes contaban con prerequisites suficientes. Pan et al. (2024) muestran que las intervenciones analíticas en LMS tienen mayor sentido cuando se conectan con decisiones instruccionales y no solo con reportes de actividad. El indicador necesita interpretación; de lo contrario, puede reforzar decisiones superficiales.

La Tabla 6 organiza posibles usos de la analítica descriptiva y diagnóstica. Su utilidad reside en mostrar que cada pregunta requiere un dato pertinente, un tipo de análisis y una decisión posible. Esta articulación evita producir tableros llenos de métricas que nadie usa y ayuda a que docentes, coordinadores y gestores conversen sobre evidencias comunes. De Witte (2023) destaca que Learning Analytics puede contribuir a resultados de aprendizaje y gestión de calidad cuando se aprovechan datos educativos accesibles para orientar decisiones.

Tabla 6.

Usos de la analítica descriptiva y diagnóstica

Pregunta institucional	Dato requerido	Análisis posible	Decisión posible
¿Dónde se concentra la reprobación?	Calificaciones por asignatura y cohorte	Tendencias, distribución, comparación histórica	Revisar diseño evaluativo y activar apoyo académico
¿Cuándo aparece la desconexión?	Accesos LMS, entregas, asistencia	Secuencia temporal semanal	Ajustar calendario, enviar alertas formativas

¿Qué recursos se usan menos?	Visualización de contenidos y descargas	Frecuencia de uso por unidad	Rediseñar recursos o mejorar orientación
¿Qué evaluaciones generan más dificultad?	Ítems, rúbricas, notas parciales	Análisis por resultado de aprendizaje	Retroalimentación específica y refuerzo conceptual
¿Quiénes requieren apoyo oportuno?	Cruce de desempeño, asistencia y tutorías	Segmentación no punitiva	Tutoría, mentoría, contacto docente
¿Qué decisiones de gestión se requieren?	Tasas, cohortes, carga académica	Comparación por carrera y periodo	Planificación de recursos y mejora curricular

2.2.2. Analítica predictiva y sistemas de alerta temprana

La analítica predictiva busca anticipar escenarios académicos mediante modelos que identifican patrones asociados con desempeño, continuidad, participación o riesgo de abandono. En educación superior, estos modelos suelen combinar datos de LMS, historial académico, evaluaciones parciales, asistencia, matrícula, características del curso y, en algunos casos, variables de contexto. Riestra-González et al. (2021) demostraron que los logs del LMS pueden apoyar predicciones tempranas del rendimiento en distintos momentos del curso, lo cual ofrece margen para intervenir antes de que el problema sea irreversible. La anticipación es valiosa cuando se convierte en apoyo, no cuando se transforma en clasificación rígida.

Los sistemas de alerta temprana funcionan como dispositivos socio-técnicos. Toman señales de riesgo, las procesan mediante reglas o modelos, generan alertas y proponen acciones de seguimiento. Sin embargo, el paso más importante no es la alerta, sino la interpretación. Fazil et al. (2024) muestran avances en modelos profundos basados en datos de participación, registros académicos y evaluación continua, pero incluso los modelos de alto desempeño requieren ser evaluados en términos de justicia, explicabilidad y utilidad pedagógica. Un modelo puede ser técnicamente preciso y, aun así, institucionalmente problemático si no activa apoyos adecuados.

La selección de variables predictivas debe hacerse con responsabilidad. Variables como entregas, accesos, participación, resultados parciales y continuidad pueden ser pertinentes; en cambio, variables sensibles o proxies de desigualdad pueden introducir sesgos si se usan sin justificación y supervisión. Cerratto y McGrath (2021) muestran que privacidad, consentimiento, transparencia y justicia son preocupaciones centrales en la ética de Learning Analytics. Por eso, la pregunta no es solo qué datos predicen mejor, sino qué datos es legítimo usar, con qué finalidad y bajo qué garantías para el estudiante.

La predicción no es destino. Un estudiante señalado por una alerta temprana no debe ser tratado como alguien condenado al fracaso, sino como una persona cuya trayectoria requiere atención. Ifenthaler y Yau (2020) insisten en que los apoyos personalizados, la retroalimentación y los andamiajes son parte esencial del valor de Learning Analytics para el éxito universitario. Esta mirada evita culpar al estudiante por señales que pueden estar vinculadas con diseño curricular, evaluación, carga académica, falta de apoyo o condiciones de vida.

Un sistema de alerta responsable debe incluir validación humana. La alerta debería llegar a docentes, tutores o coordinadores con información suficiente para conversar, contrastar y decidir. Soffer y Cohen (2024) encontraron que los estudiantes valoran los beneficios pedagógicos de Learning Analytics, pero requieren transparencia, confianza institucional y participación en los procesos de uso de datos. La confianza se debilita cuando la universidad actúa sobre datos sin explicar finalidades, límites o mecanismos de revisión.

La Figura 6 propone un ciclo de alerta temprana responsable. La lógica del ciclo evita que la analítica termine en un semáforo de riesgo sin acompañamiento. Primero se detecta una señal; luego se interpreta en contexto; después se valida con evidencia adicional; más tarde se interviene con apoyos proporcionales; finalmente se monitorea si la acción ayudó. Drăgoi et al. (2026) refuerzan esta idea al mostrar que la disposición estudiantil hacia el uso de datos depende de beneficios percibidos, control, transparencia y confianza institucional.

Figura 6.

Ciclo de alerta temprana responsable



2.3. Dashboards académicos y visualización de información

Los dashboards académicos son interfaces de visualización que organizan datos educativos para apoyar decisiones de estudiantes, docentes, coordinadores y autoridades. Su valor no está en mostrar muchos indicadores, sino en presentar información comprensible, oportuna y accionable. De Vreugd et al. (2024) señalan que los dashboards pueden apoyar la autorregulación del comportamiento de estudio, aunque su diseño debe responder a qué información se muestra, cómo se presenta y qué utilidad perciben los estudiantes. Un tablero bien diseñado no sustituye el acompañamiento; lo hace más visible y conversable.

Un Dashboard para estudiantes debería ayudar a comprender el propio avance, no a generar ansiedad comparativa. Puede mostrar progreso por unidad, retroalimentaciones pendientes, cumplimiento de actividades, recursos recomendados y próximos hitos. Kaliisa et al. (2024) advierten, a partir de una revisión sistemática, que la evidencia sobre el impacto de los dashboards en

logro académico es limitada y que muchos estudios muestran efectos pequeños o problemas metodológicos. Por eso, la visualización debe diseñarse con expectativas realistas: puede apoyar participación y autorregulación, pero no garantiza por sí sola mejora del rendimiento.

Un Dashboard para docentes debe priorizar señales de enseñanza y aprendizaje. Más que listar estudiantes en rojo, debería permitir identificar actividades con baja comprensión, recursos poco utilizados, patrones de entrega, necesidad de retroalimentación y grupos que requieren apoyo. Pan et al. (2024) destacan que las intervenciones analíticas incorporadas en LMS tienen sentido cuando informan el diseño y desarrollo de intervenciones instruccionales. Así, el tablero deja de ser una vitrina de indicadores y se convierte en una herramienta para rediseñar la práctica docente.

Para coordinadores y autoridades, los dashboards pueden apoyar decisiones sobre asignaturas críticas, carga docente, permanencia, tutorías, calidad curricular y planificación de recursos. No obstante, cuanto más alto es el nivel de gestión, mayor es el riesgo de simplificar trayectorias complejas en porcentajes agregados. De Witte (2022) vincula Learning Analytics con resultados de aprendizaje y gestión de calidad, pero esa contribución depende de que la información sea interpretada de manera contextual. La gestión basada en datos debe mirar tendencias institucionales sin perder de vista historias individuales.

La Figura 7 propone una arquitectura de dashboard académico por capas. La capa estudiante permite autorregulación; la capa curso ayuda al docente; la capa carrera apoya coordinación curricular; y la capa institución orienta calidad y planificación. Esta arquitectura recuerda que no todos los usuarios necesitan los mismos indicadores ni el mismo nivel de detalle. Afzaal y Nouri (2024) muestran que el software de Learning Analytics se orienta a actores distintos y funcionalidades variadas, por lo que el diseño debe responder a usos concretos y no a una lógica única de visualización.

Figura 7.

Arquitectura de Dashboard académico



2.3.1. Indicadores visuales para docentes y gestores

Los indicadores visuales deben responder a decisiones específicas. Para docentes, pueden ser útiles indicadores de participación, entregas, desempeño por resultado de aprendizaje, visualización de retroalimentación y evolución semanal. Para gestores, convienen tasas de aprobación, permanencia, progresión curricular, asignaturas críticas, uso de tutorías y brechas entre cohortes. Saqr y López (2024) recuerdan que visualizar datos educativos exige rigor metodológico, limpieza de datos y selección pertinente de técnicas. Un buen indicador no es el más llamativo, sino el que ayuda a tomar una decisión justa.

La visualización también debe cuidar el lenguaje. Etiquetas como “estudiante en fracaso”, “bajo valor” o “sin compromiso” pueden producir daño simbólico y reforzar lecturas deficitarias. En cambio, expresiones como “requiere contacto”, “necesita retroalimentación”, “actividad con dificultad” o “trayectoria por acompañar” orientan la intervención sin estigmatizar. Bergdahl et al. (2024) muestran que el compromiso estudiantil no puede reducirse a actividad

observable, pues incluye dimensiones que el LMS no siempre captura. El tablero debe hablar con responsabilidad pedagógica.

Para la gestión universitaria, los indicadores deben evitar la cultura del ranking simple. Comparar carreras o docentes sin considerar tamaño de cohorte, perfil de ingreso, modalidad, recursos, carga académica o cambios curriculares puede conducir a decisiones injustas. García et al. (2026) advierten que la investigación sobre rendimiento académico mediante Learning Analytics necesita incorporar mejor los contextos pedagógicos y disciplinares. Por ello, un Dashboard institucional debería incluir notas interpretativas, filtros contextuales y rutas de acción, no solo semáforos.

La Tabla 7 organiza indicadores visuales según usuario institucional. Su propósito es ayudar a diseñar tableros diferenciados, evitando que todos miren la misma información sin claridad de uso. Cuando el indicador, la finalidad y la decisión esperada están alineados, la visualización deja de ser decoración y se convierte en mediación para la mejora académica. De Vreugd et al. (2024) sostienen que la utilidad percibida de un Dashboard depende de su capacidad para apoyar procesos de autorregulación y toma de decisiones comprensibles.

Tabla 7.

Indicadores visuales por usuario institucional

Usuario	Indicador	Finalidad	Decisión esperada
Estudiante	Progreso por unidad	Autorregular estudio	Revisar pendientes y planificar tiempos
Docente	Desempeño por resultado de aprendizaje	Ajustar enseñanza	Reforzar contenidos, modificar actividad
Tutor académico	Señales combinadas de riesgo	Activar acompañamiento	Contacto temprano y plan de apoyo
Coordinador de carrera	Asignaturas críticas	Mejorar currículo	Revisar prerrequisitos, evaluación y carga
Bienestar universitario	Derivaciones y seguimiento	Sostener permanencia	Coordinar apoyo psicoeducativo o social
Autoridad académica	Tendencias de aprobación y retención	Gestión de calidad	Asignar recursos, evaluar políticas

2.3.2. Riesgos de interpretación y sobredependencia de los tableros

El principal riesgo de los dashboards es que su claridad visual produzca una falsa sensación de certeza. Un gráfico ordenado puede hacer parecer simple un fenómeno complejo: bajo rendimiento, abandono, participación o permanencia. Kaliisa et al. (2024) advierten que los dashboards no han demostrado de manera concluyente el impacto prometido sobre el rendimiento académico y que se requieren evaluaciones más rigurosas. Esta evidencia invita a usarlos con prudencia, como apoyo interpretativo y no como prueba definitiva.

Otro riesgo aparece cuando la universidad delega demasiado en la visualización. Si un tablero marca a un estudiante como “riesgo alto” y nadie conversa con él, revisa su contexto o contrasta la información, la analítica se convierte en administración de etiquetas. Cerratto y McGrath (2021) muestran que las dimensiones éticas de Learning Analytics incluyen privacidad, transparencia, consentimiento y responsabilidad institucional. La alerta debe convertirse en pregunta pedagógica: ¿qué necesita este estudiante para continuar aprendiendo?

Los sesgos visuales también pueden afectar decisiones. Escalas de color, umbrales arbitrarios, promedios agregados, rankings y comparaciones sin contexto pueden orientar interpretaciones punitivas. Soffer y Cohen (2024) muestran que los estudiantes están dispuestos a aceptar usos pedagógicos de datos, pero demandan transparencia, confianza y participación. Esta demanda obliga a que los tableros expliquen qué datos usan, qué significan los indicadores, qué límites tienen y quién puede verlos.

La inteligencia analítica universitaria alcanza su sentido cuando mejora conversaciones, decisiones y apoyos. Ningún tablero reemplaza la retroalimentación docente, la tutoría, la revisión curricular ni la escucha institucional. Khosravi et al. (2025) advierten que la convergencia entre IA generativa y Learning Analytics abre oportunidades, pero debe preservar

principios de aprendizaje profundo, autonomía, ética y privacidad. En consecuencia, una universidad basada en datos no es la que vigila más, sino la que acompaña mejor, decide con más evidencia y reconoce que cada indicador necesita contexto humano.



The background features several data visualization panels: 'Ruta de Aprendizaje' with a line graph showing an upward trend; 'Alerta Temprana' with a warning icon and text 'un estudiante se encuentra en necesidad de apoyo'; 'Comprensión de Contenidos' with a pie chart; and 'Progreso Individual' with a circular progress indicator at 85% and a bar chart. The student is a young woman with long brown hair, wearing a yellow cardigan and a backpack, sitting at a desk with a laptop and papers.

Capítulo III: Learning Analytics para mejorar el rendimiento académico y las trayectorias estudiantiles

Learning Analytics para mejorar el rendimiento académico y las trayectorias estudiantiles

3.1. Del análisis del rendimiento a la intervención educativa

Learning Analytics puede entenderse como un campo orientado a recoger, analizar, interpretar y comunicar datos sobre los estudiantes y sus procesos de aprendizaje con el propósito de generar información accionable para mejorar la enseñanza y el aprendizaje. Esta definición resulta especialmente importante porque desplaza el énfasis desde la simple acumulación de datos hacia la comprensión pedagógica de lo que ocurre en las trayectorias estudiantiles. En educación superior, el rendimiento académico no debería leerse únicamente como una calificación final, sino como el resultado provisional de múltiples interacciones entre historia académica, diseño curricular, evaluación, participación, acompañamiento, condiciones personales y oportunidades institucionales.

El paso del análisis del rendimiento a la intervención educativa exige reconocer que los indicadores no hablan por sí solos. Una baja entrega de tareas, una disminución en la participación del aula virtual o un descenso en el desempeño de una evaluación pueden señalar dificultades distintas: problemas de comprensión conceptual, desajuste en la carga académica, falta de claridad en la consigna, baja conectividad, responsabilidades familiares, ansiedad evaluativa o debilidad en los hábitos de estudio. Por ello, las universidades que incorporan analítica del aprendizaje deben evitar una lectura lineal del bajo rendimiento y promover una interpretación situada. La evidencia reciente advierte que los estudios sobre rendimiento académico con Learning Analytics aún presentan diferencias importantes en cómo conceptualizan y operacionalizan el desempeño, lo que obliga a usar los resultados con prudencia y sentido educativo (García et al., 2026).

En términos institucionales, Learning Analytics permite pasar de una cultura reactiva, centrada en revisar resultados al final del período académico, hacia una cultura de seguimiento formativo. Este cambio no consiste en vigilar más al estudiante, sino en observar con mayor responsabilidad los puntos de quiebre de la experiencia universitaria. Cuando los datos de asistencia, acceso a

recursos, actividades evaluativas, participación en foros, tutorías y progreso curricular se integran con criterios pedagógicos, la universidad puede identificar patrones de dificultad y diseñar respuestas proporcionales: refuerzo académico, rediseño de actividades, retroalimentación diferenciada, tutorías, ajustes de carga o derivación a servicios de bienestar. Así, la información deja de ser un registro administrativo y se convierte en una señal para cuidar trayectorias.

La literatura reciente también invita a evitar el entusiasmo técnico sin fundamento pedagógico. Una meta-revisión publicada en 2026 muestra que muchas revisiones sobre Learning Analytics y rendimiento académico han prestado poca atención a dimensiones educativas clave, como los contextos instruccionales, los propósitos pedagógicos, las áreas disciplinares y las teorías de aprendizaje que sostienen la intervención. Este hallazgo es decisivo para el presente libro: si los modelos analíticos no se articulan con objetivos formativos claros, pueden producir reportes interesantes, pero poco útiles para mejorar la enseñanza. En otras palabras, la pregunta no debe ser solamente qué estudiante está en riesgo, sino qué práctica, recurso, secuencia, apoyo o decisión institucional puede ayudarle a avanzar (García et al., 2026).

La intervención educativa basada en datos requiere, por tanto, un circuito de trabajo que articule distintos niveles de responsabilidad. El docente interpreta señales cercanas al aula: dudas frecuentes, errores comunes, tareas incompletas, baja interacción o dificultades en el uso de recursos. El equipo de carrera observa patrones más amplios: asignaturas con alta reprobación, secuencias curriculares problemáticas, brechas entre prerrequisitos y desempeño real. La gestión universitaria, por su parte, analiza cohortes, permanencia, disponibilidad de apoyos, distribución de recursos y calidad de los procesos académicos. Esta lectura multinivel impide reducir Learning Analytics a un tablero de control y lo convierte en una herramienta de mejora continua, siempre que sus resultados sean discutidos, contextualizados y traducidos en acciones concretas.

La Figura 8 sintetiza esta lógica de trabajo. Su propósito es mostrar que el dato solo adquiere sentido educativo cuando atraviesa una ruta de interpretación, decisión, intervención y evaluación de mejora. La figura debe leerse como un

ciclo abierto, no como una cadena mecánica: cada etapa exige juicio profesional, diálogo académico y revisión ética.

Figura 8.

Ruta dato–interpretación–intervención–mejora



3.1.1. Evaluación formativa apoyada en analítica del aprendizaje

La evaluación formativa apoyada en Learning Analytics no debe confundirse con una evaluación automatizada ni con una supervisión permanente del estudiante. Su sentido es más profundo: reunir evidencias oportunas para comprender dónde se encuentra el estudiante, hacia dónde debería avanzar y qué apoyos necesita para llegar a los resultados de aprendizaje previstos. Una revisión sistemática reciente sobre evaluación formativa y analítica del aprendizaje sostiene que este campo puede fortalecer los procesos evaluativos cuando sus resultados se alinean con modelos pedagógicos claros, especialmente con las preguntas centrales de la evaluación formativa: dónde está el estudiante, hacia dónde va y cómo puede avanzar (Banihashem et al., 2025).

Desde esta perspectiva, los datos descriptivos permiten observar lo que ha ocurrido: entregas, accesos, intentos, calificaciones parciales, participación y uso de recursos. Los datos diagnósticos ayudan a explorar posibles causas: errores recurrentes, baja interacción con materiales clave, secuencias de estudio

interrumpidas o dificultades en actividades específicas. Los datos predictivos ofrecen alertas sobre probables dificultades futuras, siempre con cautela y sin convertir la predicción en destino. Finalmente, los datos prescriptivos pueden sugerir acciones posibles, como recursos de refuerzo, tutorías, nuevas consignas, actividades de recuperación o retroalimentación focalizada. Esta progresión coincide con la idea de que la analítica solo es formativa cuando la evidencia modifica la enseñanza y abre posibilidades reales de mejora (Banihashem et al., 2025). La Tabla 8 propone una matriz básica para usar indicadores de Learning Analytics en evaluación formativa. Su utilidad no está en clasificar al estudiante, sino en ordenar la relación entre evidencia, interpretación, retroalimentación y acción docente.

Tabla 8.

Indicadores para evaluación formativa

Evidencia	Interpretación pedagógica posible	Retroalimentación sugerida	Acción docente
Bajo acceso a recursos clave	Puede existir dificultad de tiempo, conectividad, orientación o motivación	“Revisa primero este recurso breve y dime qué parte te genera duda”	Priorizar materiales esenciales y orientar la ruta de estudio
Errores repetidos en un tipo de ejercicio	Puede haber una brecha conceptual específica	“El procedimiento está iniciado, pero falta justificar este paso”	Reexplicar el concepto con ejemplo guiado
Entregas tardías o incompletas	Puede existir sobrecarga, confusión en la consigna o dificultad organizativa	“La actividad puede completarse por partes; inicia con este apartado”	Dividir la tarea, ampliar orientación y activar tutoría
Participación baja en foros	Puede haber inseguridad, poca claridad o baja pertinencia de la pregunta	“Tu aporte puede partir de una duda o ejemplo concreto”	Rediseñar la consigna para promover participación significativa
Mejora progresiva en evaluaciones parciales	Señal positiva de avance y autorregulación	“El progreso muestra que la estrategia está funcionando”	Consolidar la ruta y ofrecer desafío de mayor complejidad

La tabla permite advertir que un mismo indicador puede tener varias lecturas. Por ejemplo, el bajo acceso a una plataforma no siempre expresa desinterés; puede reflejar una dificultad tecnológica, una consigna poco comprensible o una estrategia de estudio fuera del entorno digital. Por eso, el juicio docente continúa siendo indispensable. La analítica aporta señales, pero la evaluación formativa exige conversación, contraste y decisiones contextualizadas. En este punto conviene recordar que la literatura sobre Learning Analytics ha cuestionado el predominio de análisis técnicos con poca atención al aprendizaje real, lo que obliga a recuperar el sentido pedagógico de cada indicador (Guzmán et al., 2021).

Una evaluación formativa apoyada en datos también debe considerar la dimensión emocional del aprendizaje universitario. Recibir una alerta, un reporte o una retroalimentación puede generar confianza, pero también ansiedad o sensación de vigilancia si no se comunica adecuadamente. Por ello, los indicadores deben presentarse con lenguaje orientador, no punitivo; con oportunidades de acción, no con etiquetas de fracaso; la evaluación se vuelve formativa cuando ayuda al estudiante a reconocer su progreso, comprender sus dificultades y tomar decisiones de mejora.

3.1.2. Retroalimentación personalizada y mejora del desempeño

La retroalimentación personalizada es una de las aplicaciones más prometedoras de Learning Analytics en educación superior, siempre que se entienda como diálogo académico y no como simple mensaje automático. Una revisión sistemática sobre analítica y retroalimentación en educación superior señala que Learning Analytics puede enriquecer las prácticas de feedback mediante visualizaciones, análisis de progreso, información diferenciada para docentes y estudiantes, y sistemas orientados a cerrar el ciclo entre evidencia e intervención (Banihashem et al., 2022).

Personalizar la retroalimentación implica reconocer que dos estudiantes con la misma calificación pueden necesitar orientaciones distintas. Uno puede requerir apoyo conceptual; otro, mejorar su gestión del tiempo; otro, comprender la rúbrica; y otro, recibir un desafío adicional porque ya domina los aprendizajes

básicos. Los datos permiten diferenciar estas necesidades cuando muestran patrones de avance, intentos, errores, secuencias de navegación, interacción con materiales o respuestas a evaluaciones parciales. Sin embargo, la personalización no debe convertirse en sobresegmentación ni en una clasificación rígida. El propósito es ofrecer una orientación más justa y pertinente, no encerrar al estudiante en un perfil automático.

La investigación reciente sobre feedback altamente informativo apoyado en Learning Analytics subraya que la utilidad de la retroalimentación depende también de la alfabetización del estudiante para interpretarla y usarla. Dicho de otro modo, no basta con entregar información precisa; es necesario ayudar al estudiante a comprender qué significa, cómo priorizarla y qué acción concreta puede realizar después de recibirla (Weidlich et al., 2025).

En la práctica universitaria, una retroalimentación personalizada puede adoptar distintas formas: mensajes breves vinculados a errores frecuentes, recomendaciones de recursos según desempeño, visualizaciones de progreso, alertas de autorregulación, comentarios docentes apoyados en analíticas de participación o sugerencias de tutoría cuando se detectan dificultades persistentes. La clave está en que cada retroalimentación sea comprensible, oportuna y accionable. Decir “su rendimiento es bajo” aporta poco; decir “revise el criterio 2 de la rúbrica, compare su respuesta con el ejemplo resuelto y entregue una versión corregida antes del viernes” abre una posibilidad real de mejora.

La mejora del desempeño académico, por tanto, no surge de la retroalimentación como dato aislado, sino de su integración en una cultura pedagógica de acompañamiento. Cuando el estudiante recibe información clara y el docente puede observar si esa información produce cambios en la actividad posterior, la retroalimentación deja de ser un cierre de la evaluación y se convierte en parte del aprendizaje. Learning Analytics ayuda a sostener este proceso en grupos numerosos, modalidades híbridas o asignaturas con alta complejidad, pero su valor depende de mantener el vínculo humano: preguntar, orientar, escuchar y ajustar.

3.2. Aprendizaje adaptativo y rutas diferenciadas

El aprendizaje adaptativo se refiere a la posibilidad de ajustar rutas, recursos, ritmos, actividades y apoyos según evidencias sobre el avance de los estudiantes. En educación superior, esta idea responde a una realidad evidente: no todos los estudiantes llegan con los mismos conocimientos previos, condiciones de estudio, competencias digitales, experiencias académicas o necesidades de acompañamiento. Una revisión de alcance publicada en 2024 encontró que el aprendizaje personalizado adaptativo en educación superior puede asociarse con mejoras en rendimiento académico y participación, aunque también reconoce limitaciones tecnológicas y la necesidad de seguir refinando su implementación (Du Plooy et al., 2024).

Personalizar no significa bajar la exigencia académica ni fragmentar el currículo en caminos inconexos. Significa construir condiciones más justas para que los estudiantes puedan alcanzar aprendizajes relevantes desde puntos de partida diferentes. En este sentido, Learning Analytics permite identificar qué estudiantes requieren una explicación adicional, qué grupo necesita practicar una habilidad específica, qué recurso resulta poco utilizado, qué actividad genera abandono o qué secuencia produce mejores resultados. La adaptación, por tanto, no elimina el criterio docente; lo vuelve más informado y sensible a las trayectorias reales.

Las rutas diferenciadas pueden operar en varios niveles. En un nivel micro, el estudiante recibe recursos de refuerzo, ejercicios graduados, retroalimentación específica o actividades de profundización. En un nivel meso, el docente rediseña una unidad, modifica la secuencia de actividades, ajusta la evaluación o reorganiza tiempos de entrega. En un nivel macro, la carrera identifica asignaturas críticas, trayectorias con mayor riesgo de rezago o brechas de desempeño entre cohortes. Esta articulación entre aula, currículo y gestión evita que el aprendizaje adaptativo sea solo una función de plataforma y lo convierte en una estrategia institucional de acompañamiento.

La evidencia analítica debe integrarse con información pedagógica y contextual. Un sistema adaptativo puede detectar que un estudiante no completó una actividad, pero difícilmente comprenderá por sí solo si la causa fue una dificultad

cognitiva, una barrera de accesibilidad, una situación personal o una consigna mal diseñada. Por ello, la adaptación responsable requiere combinar datos de plataforma con observación docente, resultados de evaluación, diálogo tutorial y criterios de inclusión. Esta combinación protege al estudiante de interpretaciones reduccionistas y permite diseñar apoyos más precisos. La Figura 9 presenta un modelo de aprendizaje adaptativo basado en datos. Su función es ordenar los componentes mínimos de una ruta diferenciada: diagnóstico, selección de ruta, recurso, evaluación y ajuste.

Figura 9.

Modelo de aprendizaje adaptativo basado en datos



El modelo muestra que la adaptación no termina cuando el sistema recomienda un recurso. El punto decisivo está en revisar si la recomendación produjo aprendizaje, participación o mayor claridad. Si el estudiante no mejora, la respuesta no debe ser insistir en la misma ruta, sino reinterpretar la señal y buscar otra forma de apoyo. Esta lógica evita que Learning Analytics funcione como una receta automática. Cada trayectoria cuenta, y cada ajuste debe

sostener la exigencia académica sin olvidar que aprender también implica tiempo, confianza y condiciones adecuadas.

3.2.1. Variables para personalizar el aprendizaje universitario

La personalización académica requiere seleccionar variables relevantes sin caer en una acumulación indiscriminada de datos. Entre las variables más utilizadas se encuentran el rendimiento previo, el ritmo de avance, la participación en el entorno virtual, el dominio conceptual, la interacción con recursos, la asistencia, los intentos de evaluación, las solicitudes de apoyo y las necesidades de accesibilidad. Sin embargo, la literatura reciente advierte que las variables predictivas no siempre tienen el mismo valor en todos los contextos, disciplinas o poblaciones estudiantiles. Por ello, deben interpretarse como señales dinámicas y no como rasgos fijos del estudiante (García et al., 2026). La Tabla 9 organiza algunas variables posibles para personalizar el aprendizaje universitario. Su propósito es mostrar que cada variable debe vincularse con una fuente, una interpretación prudente y un posible ajuste pedagógico.

Tabla 9.

Variables de personalización académica

Variable	Fuente de datos	Interpretación posible	Posible ajuste
Rendimiento previo	Historial académico, diagnósticos iniciales	Brecha de conocimientos o fortaleza acumulada	Nivelación, refuerzo o profundización
Ritmo de avance	Fechas de entrega, progreso en módulos	Dificultad de organización, carga o comprensión	Calendario guiado, microtarefas, tutoría
Participación	Foros, accesos, interacción en LMS	Vinculación académica o dificultad de participación	Rediseño de actividades colaborativas
Dominio conceptual	Evaluaciones parciales, rúbricas, ejercicios	Comprensión parcial o error recurrente	Explicación focalizada y práctica guiada
Necesidades de apoyo	Tutorías, encuestas, reportes institucionales	Barreras académicas, digitales o personales	Acompañamiento diferenciado y derivación

Accesibilidad	Uso de formatos, ajustes, tecnologías de apoyo	Barreras de acceso a materiales o actividades	Recursos accesibles y diseño universal
---------------	--	---	---

La tabla evita una lectura deficitista porque no define al estudiante como “bueno”, “malo”, “activo” o “pasivo”. En lugar de etiquetas, propone relaciones entre evidencias y apoyos. Esta diferencia es fundamental: una variable no debe convertirse en identidad. Un estudiante con bajo acceso durante una semana no es un estudiante desinteresado; puede estar atravesando una barrera temporal. Un estudiante con bajo desempeño en un criterio no es incapaz; puede necesitar otra mediación. La personalización ética reconoce que las trayectorias cambian y que los apoyos deben ajustarse con flexibilidad.

En consecuencia, las variables de personalización deben revisarse periódicamente. Un modelo que funcionó en una cohorte puede no funcionar en otra; una señal relevante en una asignatura práctica puede ser insuficiente en una asignatura teórica; un indicador útil en modalidad virtual puede perder fuerza en modalidad presencial. Learning Analytics debe operar como una práctica de aprendizaje institucional: probar, evaluar, corregir y documentar. Solo así la personalización evita convertirse en automatización superficial y se acerca a una pedagogía universitaria más justa.

3.2.2. Diseño instruccional basado en evidencias analíticas

El diseño instruccional basado en evidencias analíticas consiste en usar datos de aprendizaje para mejorar actividades, recursos, secuencias, consignas, tiempos, evaluaciones y experiencias dentro del curso. Esta perspectiva resulta especialmente útil porque muchas dificultades académicas no se originan únicamente en el estudiante, sino en decisiones de diseño que pueden ser revisadas. Un foro con baja participación puede tener una consigna poco desafiante; un recurso con escaso uso puede estar mal ubicado; una evaluación con errores generalizados puede indicar que el contenido previo no preparó suficientemente al grupo. El dato, entonces, ayuda a mirar el curso con honestidad pedagógica. La Tabla 10 presenta una matriz de decisiones de diseño instruccional basadas en datos. Su finalidad es convertir señales analíticas en posibilidades concretas de rediseño.

Tabla 10.

Decisiones de diseño instruccional basadas en datos

Señal analítica	Problema posible	Rediseño instruccional	Evidencia esperada
Muchos estudiantes abandonan un video extenso	Sobrecarga cognitiva o baja segmentación	Dividir el video en cápsulas breves con preguntas intermedias	Mayor finalización y mejores respuestas
Baja participación en foro	Consigna cerrada o poco relevante	Formular pregunta situada, con ejemplo y rol de participación	Más intervenciones argumentadas
Alto error en un criterio de rúbrica	Criterio poco comprendido o mal enseñado	Crear ejemplo comentado y mini actividad de práctica	Menos errores en segunda entrega
Entregas tardías recurrentes	Calendario poco claro o tarea demasiado amplia	Dividir la tarea en hitos parciales	Mejora en cumplimiento y calidad
Uso bajo de material complementario	Recurso no integrado a la actividad	Vincular el recurso con una tarea concreta	Mayor consulta y aplicación del recurso

El valor de esta tabla está en que desplaza la pregunta desde “¿por qué el estudiante no responde?” hacia “¿qué puede hacer el diseño del curso para favorecer una mejor respuesta?”. Esta mirada no exonera al estudiante de su responsabilidad académica, pero sí evita convertirlo en único responsable de las dificultades. Un capítulo académico reciente sobre analítica de datos y prácticas de evaluación en educación superior muestra que la analítica puede apoyar la retroalimentación, el diseño de aprendizaje y la alineación evaluativa cuando se usa para revisar cómo se conectan actividades, resultados de aprendizaje y desempeño estudiantil (Rienties et al., 2024).

El rediseño instruccional basado en datos también requiere distinguir entre señales débiles y señales robustas. No conviene modificar un curso completo por una observación aislada; sí es pertinente revisar una actividad cuando varias cohortes muestran el mismo patrón de dificultad. Tampoco basta con observar métricas de acceso: un estudiante puede abrir un recurso sin comprenderlo, o comprender un contenido mediante materiales externos. Por ello, los datos de

plataforma deben complementarse con evidencias de desempeño, encuestas breves, análisis de productos académicos y conversaciones con estudiantes.

En síntesis, Learning Analytics mejora el diseño instruccional cuando permite cerrar el ciclo entre evidencia y acción. La secuencia sería: observar una señal, formular una hipótesis pedagógica, rediseñar un elemento del curso, aplicar la mejora y evaluar si produjo cambios. Este ciclo convierte al docente en investigador de su propia práctica y a la universidad en una organización que aprende de sus procesos. La tecnología es importante, pero el cambio real ocurre cuando el dato modifica una decisión pedagógica concreta.

3.3. Permanencia, inclusión y acompañamiento estudiantil

La relación entre Learning Analytics, permanencia e inclusión debe construirse desde una premisa ética: la alerta debe activar apoyo, no estigmatización. En educación superior, permanecer no significa únicamente seguir matriculado; implica participar, comprender, avanzar, sentirse parte y contar con condiciones razonables para sostener la trayectoria. Una revisión sistemática sobre Learning Analytics, inclusión y estudiantes con discapacidad muestra que este campo tiene potencial para reducir discriminación, aumentar retención y validar diseños de aprendizaje para grupos marginados, aunque también reconoce que la investigación empírica en inclusión sigue siendo limitada (Khalil et al., 2024).

El abandono universitario no puede explicarse como una falla individual. Suele estar relacionado con factores académicos, económicos, emocionales, familiares, institucionales, digitales y curriculares. Learning Analytics ayuda a detectar señales tempranas, pero la respuesta debe ser integral. Un estudiante que deja de conectarse, reprueba una evaluación o acumula ausencias puede estar comunicando una dificultad que aún no ha sido escuchada. Desde una mirada pedagógicamente sensible, el indicador no debe cerrar el diagnóstico; debe abrir una conversación. La universidad basada en datos no es la que observa más para sancionar, sino la que comprende mejor para acompañar.

Las revisiones sobre éxito académico en educación superior muestran que Learning Analytics puede apoyar la continuidad y finalización de estudios, aunque todavía se requiere evidencia más rigurosa y de gran escala sobre su efectividad. Este matiz es importante: los datos pueden mejorar la capacidad de

respuesta institucional, pero no garantizan por sí mismos la permanencia. Su aporte depende de la calidad de los modelos, de la oportunidad de las intervenciones, de la coordinación entre áreas y de la existencia real de apoyos disponibles (Ifenthaler & Yau, 2020). La Figura 10 representa una arquitectura de analítica para la permanencia inclusiva. El diseño se organiza por capas porque la permanencia no depende de una sola acción, sino de un sistema articulado de detección, comprensión, apoyo, seguimiento y pertenencia.

Figura 10.

Analítica para la permanencia inclusiva



La figura subraya que la inclusión no aparece al final del proceso, sino en cada decisión. Detectar sin contexto puede producir etiquetas; contextualizar sin apoyo puede quedarse en diagnóstico; apoyar sin seguimiento puede dispersar recursos; hacer seguimiento sin pertenencia puede olvidar que la continuidad también depende del vínculo con la institución. Learning Analytics debe ayudar a que la universidad pregunte quién está quedando atrás, por qué está ocurriendo y qué responsabilidad institucional existe en esa trayectoria.

La permanencia inclusiva exige, además, gobernanza de datos. Las investigaciones sobre analítica centrada en lo humano advierten que excluir a estudiantes y docentes del diseño de sistemas de Learning Analytics puede generar desconfianza y herramientas poco alineadas con las necesidades

reales. También se insiste en equilibrar la intervención humana y la automatización, fortalecer la transparencia y considerar seguridad, fiabilidad y confianza como principios de diseño (Alfredo et al., 2024).

3.3.1. Tutorías académicas orientadas por datos

Las tutorías académicas orientadas por datos constituyen una de las formas más humanas de aplicar Learning Analytics. Su punto de partida no es el indicador, sino el encuentro tutorial que permite comprender qué está ocurriendo en la trayectoria del estudiante. Los datos pueden ayudar al tutor a preparar mejor la conversación: revisar entregas, participación, calificaciones parciales, asistencia, ritmo de avance o alertas previas.

Sin embargo, la tutoría no debe convertirse en lectura de tablero. El dato apenas abre la puerta; la escucha, la pregunta y el acuerdo de apoyo sostienen el proceso. La Tabla 11 organiza algunos usos posibles de datos en tutorías universitarias. Su finalidad es mostrar cómo una señal puede transformarse en una pregunta tutorial y luego en una acción de acompañamiento.

Tabla 11.

Uso de datos en tutorías universitarias

Señal	Pregunta tutorial	Acción de apoyo	Seguimiento
Dos evaluaciones parciales con bajo desempeño	¿Qué parte del contenido resultó más difícil y cómo estudiaste?	Plan breve de refuerzo y recurso focalizado	Revisar desempeño en actividad posterior
Baja conexión al LMS	¿Has tenido dificultades de acceso, tiempo o comprensión de la plataforma?	Orientación tecnológica o ruta mínima de estudio	Verificar acceso y avance semanal
Entregas incompletas	¿La dificultad está en la consigna, el tiempo o el contenido?	Dividir tarea y acordar entrega por etapas	Revisar primer avance
Ausencias recurrentes	¿Qué situación está afectando tu asistencia?	Derivación a bienestar o ajuste académico razonable	Confirmar continuidad y apoyo

Mejora sostenida	¿Qué estrategia te está funcionando?	Reforzar hábitos y proponer desafío mayor	Observar mantenimiento del progreso
------------------	--------------------------------------	---	-------------------------------------

Esta matriz recuerda que la tutoría basada en datos debe formular preguntas, no dictar sentencias. Una señal de riesgo puede orientar el diálogo, pero no reemplaza la explicación del estudiante ni la experiencia del tutor. En la práctica, una buena tutoría combina evidencia y cuidado: “observé que no has entregado las dos últimas actividades; quiero entender si el problema está en el contenido, en el tiempo o en otra situación”. Ese tipo de comunicación evita culpabilizar y abre una ruta de responsabilidad compartida.

Los sistemas de alerta temprana pueden apoyar la labor tutorial cuando identifican estudiantes que podrían requerir contacto oportuno. Sin embargo, la investigación sobre identificación de estudiantes en riesgo muestra que las alertas deben vincularse con intervenciones de retroalimentación y acompañamiento, no solo con clasificación. Un estudio reciente en *Journal of Learning Analytics* destaca precisamente la relación entre identificación temprana y feedback intervention, lo que refuerza la idea de que detectar sin intervenir tiene escaso valor pedagógico (Dai et al., 2025).

La tutoría orientada por datos también fortalece la gestión universitaria cuando permite documentar necesidades recurrentes. Si muchos estudiantes de una asignatura solicitan apoyo por la misma dificultad, la respuesta no debería limitarse a tutorías individuales; conviene revisar el diseño del curso, los prerrequisitos, la carga de trabajo o la evaluación. De este modo, la tutoría no solo acompaña casos particulares, sino que produce conocimiento institucional sobre las condiciones que favorecen o dificultan las trayectorias estudiantiles.

3.3.2. Riesgo académico, abandono y respuesta institucional temprana

El riesgo académico debe entenderse como una condición situada y modificable, no como una identidad del estudiante. Esta distinción es decisiva para evitar prácticas injustas. Decir que un estudiante “está en riesgo” no significa que esté destinado al fracaso; significa que existen señales que justifican una respuesta

temprana, proporcional y respetuosa. La literatura sobre Learning Analytics para identificar estudiantes en riesgo en educación superior muestra que las alertas pueden ser útiles, pero también exige cautela en su interpretación, especialmente cuando los indicadores pueden reflejar desigualdades previas o condiciones no observadas por el modelo (Foster y Siddle, 2020).

Una respuesta institucional temprana requiere definir umbrales, responsables y rutas de intervención. No basta con que un sistema emita una alerta; debe existir un protocolo que indique quién revisa la información, cómo se valida, cómo se contacta al estudiante, qué apoyos se ofrecen y cómo se evalúa la respuesta. Además, la intervención debe ser gradual: no toda señal exige la misma acción. Una ausencia aislada puede requerir un recordatorio; un patrón de desconexión y bajo desempeño puede activar tutoría; una dificultad persistente puede requerir coordinación con bienestar estudiantil, accesibilidad, coordinación académica o apoyo financiero.

El abandono universitario suele ser el desenlace visible de dificultades acumuladas. Por eso, Learning Analytics tiene mayor valor cuando actúa en fases tempranas de la trayectoria: primeras semanas del período, primeras evaluaciones, primeros signos de desconexión, primeros incumplimientos de entregas. No se trata de anticipar para controlar, sino de anticipar para abrir alternativas. Si la universidad espera hasta el final del semestre, muchas decisiones llegan tarde. En cambio, una alerta oportuna puede activar una conversación, una recuperación, una tutoría o un ajuste que preserve la continuidad académica. La Figura 11 propone un sistema de respuesta temprana al abandono. Su estructura muestra que la detección debe ir acompañada de priorización, contacto, intervención y evaluación de resultados.

Figura 11.

Sistema de respuesta temprana al abandono



La figura permite observar que la respuesta temprana no termina con contactar al estudiante. La universidad debe evaluar si la intervención fue pertinente y si produjo algún cambio. Si el estudiante no responde, no conviene asumir desinterés de inmediato; puede ser necesario cambiar el canal de comunicación, involucrar al tutor, revisar barreras digitales o activar apoyo psicosocial. La ética del acompañamiento exige insistir con cuidado, respetar la autonomía del estudiante y proteger su privacidad.

El cierre de este capítulo puede formularse así: Learning Analytics mejora el rendimiento académico y las trayectorias estudiantiles cuando convierte los datos en decisiones pedagógicas, tutoriales e institucionales responsables. Su aporte no está en predecir quién fracasará, sino en ampliar la capacidad de la universidad para intervenir a tiempo, rediseñar experiencias, personalizar apoyos, fortalecer la evaluación formativa y sostener la permanencia con equidad. La universidad basada en datos no debe ser una universidad que vigila más, sino una que acompaña mejor, aprende de sus evidencias y reconoce que detrás de cada indicador hay una historia académica que todavía puede cambiar.

An illustration of a young woman with long brown hair, wearing a yellow cardigan over a white shirt and a blue backpack, sitting at a wooden desk. She is holding a tablet and looking at it. On the desk is a laptop and some papers. The background is a semi-transparent overlay of various data visualization charts and graphs.

Capítulo IV: Gestión universitaria, ética y gobernanza de Learning Analytics

Ruta de Aprendizaje



Alerta Tempra
un estudiante se esu
en necesita de apo



**Comprensión
de Contenidos**



**Progre
Individ**



Gestión universitaria, ética y gobernanza de Learning Analytics

4.1. Gestión universitaria basada en evidencia

La gestión universitaria basada en evidencia puede entenderse como la capacidad institucional para convertir datos académicos, administrativos y pedagógicos en decisiones oportunas, contextualizadas y orientadas a la mejora. En el campo de Learning Analytics, esta perspectiva no se limita a producir reportes o tableros, sino que busca comprender cómo aprenden los estudiantes, qué condiciones favorecen su permanencia y qué procesos requieren ajustes institucionales. Como advierten Tsai et al. (2021), la implementación de analítica del aprendizaje no es solo un desafío técnico, sino también sociocultural, porque depende de la confianza, la interpretación compartida y la capacidad de actuar sobre la información.

Desde esta perspectiva, la universidad basada en datos no debe confundirse con una universidad obsesionada por medirlo todo. La evidencia adquiere valor cuando permite mirar con mayor claridad las trayectorias estudiantiles, detectar puntos de quiebre y diseñar apoyos antes de que las dificultades se conviertan en abandono. La analítica institucional puede aportar a la planificación académica, al seguimiento de cohortes, a la organización de tutorías, a la revisión de asignaturas críticas y a la distribución de recursos, siempre que sus resultados se interpreten con prudencia y no como diagnósticos definitivos sobre el estudiante (De Silva et al., 2022).

En términos de gestión, Learning Analytics permite articular información que con frecuencia se encuentra dispersa entre sistemas de admisión, plataformas LMS, registros de evaluación, bienestar estudiantil, bibliotecas digitales y unidades de calidad. Esta integración no busca vigilar más, sino comprender mejor. Cuando los datos se conectan con preguntas institucionales pertinentes —por ejemplo, qué asignaturas concentran mayor reprobación, qué carreras presentan alertas tempranas de deserción o qué estudiantes requieren acompañamiento académico— la gestión deja de reaccionar tarde y empieza a construir respuestas preventivas.

La literatura reciente sugiere que la adopción de Learning Analytics en educación superior requiere madurez institucional, infraestructura, formación, políticas claras y coordinación entre actores. Freitas et al. (2024) proponen un modelo de madurez que reconoce dimensiones técnicas, humanas, pedagógicas y éticas, lo que confirma que la analítica no se instala únicamente con software. La información debe circular hacia quienes pueden tomar decisiones: docentes, coordinadores de carrera, unidades de bienestar, autoridades académicas y equipos de calidad.

Conviene precisar que los datos educativos no explican por sí solos el rendimiento académico. Una baja participación en el LMS puede expresar desinterés, pero también dificultades de conectividad, problemas de salud, sobrecarga laboral, responsabilidades familiares o poca claridad en la actividad propuesta. Por ello, la gestión universitaria basada en evidencia debe combinar indicadores cuantitativos con interpretación pedagógica, escucha estudiantil y juicio profesional.

En esta línea, Hernández et al. (2025) advierten que muchas investigaciones sobre resultados de aprendizaje siguen usando calificaciones finales como principal medida, lo cual exige cautela para no reducir el aprendizaje a una sola expresión numérica. La Figura 12 sintetiza un modelo de gestión universitaria basada en evidencia, organizado como un ciclo de mejora continua. El modelo muestra que los datos solo producen valor cuando pasan por análisis situado, decisión institucional, intervención pedagógica o administrativa y evaluación posterior de sus efectos.

Figura 12.

Modelo de gestión universitaria basada en evidencia



4.1.1. Indicadores institucionales para la mejora académica

Los indicadores institucionales son señales organizadas que permiten observar el comportamiento académico de una universidad en relación con sus estudiantes, programas, procesos y resultados. En Learning Analytics, estos indicadores no deben funcionar como etiquetas de éxito o fracaso, sino como puntos de entrada para formular preguntas más profundas: qué está ocurriendo, dónde ocurre, a quién afecta, qué apoyos existen y qué decisiones pueden mejorar la experiencia formativa. Medir no equivale a comprender; el indicador necesita interpretación.

Entre los indicadores más relevantes para la mejora académica se encuentran aprobación, reprobación, retención, permanencia, eficiencia terminal, progresión curricular, deserción, satisfacción estudiantil, participación en entornos digitales y uso de servicios de apoyo. Su lectura adquiere sentido cuando se analiza por cohorte, carrera, modalidad, asignatura, semestre y perfil de ingreso, evitando comparaciones simplistas entre estudiantes o programas. La evidencia latinoamericana muestra que las universidades ya recopilan datos, pero muchas

veces enfrentan dificultades de confiabilidad, integración y políticas de uso (Hilliger et al., 2020).

La aprobación y la reprobación, por ejemplo, no deberían leerse como responsabilidad exclusiva del estudiante. Una tasa elevada de reprobación en una asignatura puede indicar vacíos previos, problemas de diseño curricular, metodologías poco ajustadas, criterios de evaluación poco claros o falta de retroalimentación oportuna. De la misma manera, la retención y la eficiencia terminal permiten observar si la institución está acompañando adecuadamente las trayectorias, pero requieren análisis contextual para no convertir la permanencia en una exigencia administrativa desconectada de la vida real de los estudiantes.

La satisfacción estudiantil también debe interpretarse con cuidado. No se trata de reducir la calidad a percepción del usuario, sino de reconocer que la experiencia universitaria incluye claridad de orientación, acceso a recursos, pertinencia de la retroalimentación, comunicación docente, bienestar y sentido de pertenencia. Soffer y Cohen (2024) muestran que los estudiantes pueden aceptar usos pedagógicos de sus datos cuando perciben beneficios, confianza institucional y transparencia; por tanto, incluso los indicadores de percepción pueden aportar a una gestión más sensible y responsable. La Tabla 12 organiza indicadores institucionales de mejora académica y los vincula con fuentes de información, lectura institucional y decisiones posibles. Su propósito es evitar un uso burocrático de los datos y mostrar que cada indicador debe conducir a una acción educativa o de gestión.

Tabla 12.

Indicadores institucionales de mejora académica

Indicador	Fuente de datos	Lectura institucional	Decisión posible
Aprobación por asignatura	Sistema académico, actas de calificaciones	Identifica asignaturas con desempeño crítico o variaciones entre cohortes	Revisión de sílabos, tutorías focalizadas, acompañamiento docente
Retención semestral	Matrícula, registros de continuidad	Permite observar permanencia entre periodos académicos	Activar alertas tempranas, fortalecer orientación y bienestar

Eficiencia terminal	Historial académico por cohorte	Muestra proporción de estudiantes que culminan en tiempo esperado	Revisar cuellos de botella curriculares y prácticas de titulación
Progresión curricular	Créditos aprobados, prerequisites, avance en malla	Evidencia retrasos o acumulación de asignaturas pendientes	Diseñar rutas de recuperación, consejería académica y flexibilización
Deserción o retiro	Matrícula, solicitudes de retiro, inactividad	Señala interrupciones de trayectoria que requieren explicación contextual	Entrevistas de salida, apoyos socioeconómicos, seguimiento preventivo
Participación en LMS	Registros de acceso, actividades, entregas	Permite detectar desconexión o baja interacción con el curso	Retroalimentación temprana, rediseño de actividades, tutorías
Satisfacción estudiantil	Encuestas, grupos focales, servicios de atención	Aporta percepción sobre experiencia, apoyo y comunicación	Planes de mejora por programa, capacitación docente, ajustes de servicio

4.1.2. Calidad, acreditación y mejora continua apoyadas en Learning Analytics

Learning Analytics puede fortalecer los procesos de aseguramiento de la calidad cuando se integra como una práctica de aprendizaje institucional, no como una herramienta para producir evidencias de última hora antes de una evaluación externa. La calidad universitaria no se reduce al cumplimiento de estándares; implica comprender si los procesos formativos generan condiciones reales para que los estudiantes aprendan, permanezcan, progresen y culminen sus estudios con sentido académico y profesional.

En los sistemas de acreditación, los datos suelen emplearse para demostrar cumplimiento: tasas de titulación, producción académica, satisfacción, empleabilidad, eficiencia, infraestructura y resultados de aprendizaje. Learning Analytics amplía esta mirada porque permite observar procesos, no solo resultados finales. Por ejemplo, puede mostrar cómo se distribuye la participación durante el semestre, dónde se concentran retrasos en entregas,

qué actividades generan mayor dificultad o qué patrones anticipan abandono. Esta información puede alimentar planes de mejora más precisos y menos declarativos.

La mejora continua apoyada en Learning Analytics exige cerrar el ciclo entre diagnóstico, intervención y evaluación. Un tablero que muestra riesgo académico no mejora nada por sí solo; mejora cuando activa tutorías, rediseños didácticos, ajustes de evaluación, acompañamiento psicoeducativo o decisiones de gestión curricular. En este sentido, Pan et al. (2024) señalan que las intervenciones incorporadas en LMS ofrecen evidencia útil para el diseño y aplicación de acciones pedagógicas, aunque sus efectos deben analizarse con cuidado y no asumirse automáticamente.

La acreditación también puede beneficiarse de una analítica orientada a equidad. No basta con saber cuántos estudiantes aprueban; conviene analizar quiénes aprueban, en qué condiciones, con qué apoyos y qué brechas persisten entre grupos, modalidades o trayectorias. Esta lectura evita que la calidad se transforme en una vitrina de indicadores agregados que ocultan desigualdades internas. Desde una gobernanza responsable, la calidad debe mirar tanto el desempeño institucional como la justicia de las oportunidades que ofrece.

Por ello, Learning Analytics puede convertirse en una infraestructura ética para la mejora universitaria si se usa con transparencia, participación y supervisión humana. La calidad académica se fortalece cuando la universidad aprende de sus propios datos, conversa sobre ellos con sus comunidades y los convierte en decisiones verificables. En lugar de preparar información solo para la acreditación, la institución puede construir una cultura en la que la evidencia acompañe la planificación, la docencia, la evaluación y el cuidado de las trayectorias estudiantiles.

4.2. Gobernanza de datos educativos

La gobernanza de datos educativos es el conjunto de políticas, roles, procedimientos, responsabilidades y criterios éticos que regulan cómo una institución recolecta, integra, almacena, analiza, comparte y utiliza la información de sus estudiantes. En Learning Analytics, la gobernanza no es un aspecto accesorio: es la condición que permite que los datos se usen para mejorar el

aprendizaje sin vulnerar derechos, confianza ni autonomía. Como sostienen Pargman y McGrath (2021), la ética en Learning Analytics requiere investigación empírica, claridad conceptual y atención a brechas todavía abiertas.

Una política de gobernanza debe definir qué datos se recogen, con qué propósito, durante cuánto tiempo se conservan, quién puede acceder, bajo qué niveles de autorización, cómo se protegen y qué mecanismos existen para revisar usos indebidos. Esta definición evita que la analítica se convierta en acumulación indefinida de información estudiantil. No todo dato disponible debe ser usado, y no todo uso técnicamente posible resulta pedagógicamente legítimo.

La gobernanza también ordena responsabilidades. Las autoridades universitarias deben garantizar políticas y recursos; las unidades tecnológicas deben asegurar interoperabilidad, seguridad y trazabilidad; los docentes deben interpretar datos con criterio pedagógico; los equipos de bienestar deben activar apoyos; y los estudiantes deben conocer de manera comprensible qué información se utiliza y para qué. La confianza estudiantil también se gestiona, especialmente cuando los datos pueden influir en decisiones académicas o administrativas.

La literatura sobre adopción institucional muestra que las universidades suelen enfrentar desafíos relacionados con calidad de datos, cultura organizacional, competencias analíticas, privacidad, ética e integración tecnológica. Wasson et al. (2024), a partir del caso noruego, identifican dilemas vinculados con datos, aprendizaje, gobernanza y competencia, lo que confirma que Learning Analytics exige decisiones políticas y pedagógicas, no solo soluciones informáticas.

En contextos latinoamericanos, esta discusión adquiere particular relevancia porque muchas instituciones han recopilado datos durante años, pero no siempre cuentan con marcos claros para regular su tratamiento, compartirlos entre unidades o convertirlos en apoyos efectivos. Hilliger et al. (2020) encontraron que la falta de sistemas confiables y políticas de uso de datos constituye un obstáculo para adoptar Learning Analytics en universidades de la región. La gobernanza, por tanto, no frena la innovación; la vuelve sostenible.

La Figura 13 presenta un marco de gobernanza de datos para Learning Analytics. Sus capas muestran que la ética, la seguridad y la mejora deben atravesar todo el proceso, desde la política institucional hasta la intervención educativa.

Figura 13.

Marco de gobernanza de datos para Learning Analytics



4.2.1. Privacidad, consentimiento y protección de datos estudiantiles

La privacidad en Learning Analytics no puede reducirse a un aviso legal extenso que el estudiante acepta sin comprender. Implica reconocer que los datos educativos forman parte de la vida académica de una persona y pueden revelar hábitos, dificultades, ausencias, emociones indirectas, ritmos de aprendizaje o condiciones de vulnerabilidad. Por ello, la protección de datos estudiantiles exige una comunicación clara, accesible y honesta sobre los usos previstos de la información.

El consentimiento informado debe entenderse como un proceso, no como una firma aislada. La universidad debe explicar qué datos se recogerán, qué

finalidades tendrán, qué beneficios se esperan, qué riesgos existen, quién tendrá acceso, qué decisiones podrían derivarse y qué opciones tiene el estudiante para consultar, corregir o solicitar límites razonables. Jones (2019) propuso mecanismos de consentimiento para Learning Analytics en educación superior orientados a promover privacidad y autonomía estudiantil, una preocupación que sigue vigente en la literatura reciente.

La minimización de datos es un principio central: se debe recopilar solo la información necesaria para finalidades educativas justificadas. Usar datos sensibles, variables demográficas o información de bienestar requiere una justificación reforzada, medidas de protección y revisión ética. Korir et al. (2023) muestran que las preocupaciones estudiantiles pueden variar según el contexto de uso y el tipo de intercambio de datos, lo que obliga a diseñar políticas sensibles a la integridad contextual de la información.

La anonimización y la seudonimización pueden reducir riesgos, pero no eliminan todas las posibilidades de reidentificación, especialmente cuando se cruzan bases de datos. Por eso, la seguridad técnica debe complementarse con controles de acceso, auditorías, registros de trazabilidad, capacitación de usuarios y sanciones ante usos indebidos. La protección de datos no es solo responsabilidad del área tecnológica; compromete a toda la institución. La Tabla 13 propone criterios éticos para el uso de datos estudiantiles. Su función es orientar decisiones institucionales antes de implementar dashboards, modelos predictivos o sistemas de alerta temprana.

Tabla 13.

Criterios éticos para uso de datos estudiantiles

Criterio	Pregunta orientadora	Riesgo	Medida responsable
Finalidad legítima	¿Para qué se usará el dato y cómo mejora el aprendizaje o el acompañamiento?	Recolección sin propósito educativo claro	Definir finalidades explícitas y revisables
Minimización	¿Es indispensable este dato para la decisión que se desea tomar?	Acumulación excesiva de información	Recoger solo datos necesarios y pertinentes

Transparencia	¿El estudiante entiende qué datos se usan y con qué consecuencias?	Consentimiento formal pero no informado	Comunicación clara, accesible y periódica
Control estudiantil	¿El estudiante puede consultar, corregir o preguntar por sus datos?	Pérdida de autonomía y confianza	Canales de consulta, revisión y reclamo
Seguridad	¿Quién accede al dato y cómo se protege?	Filtración, uso indebido o acceso no autorizado	Roles, permisos, cifrado, auditoría y trazabilidad
No discriminación	¿El uso del dato puede afectar injustamente a un grupo?	Sesgos, estigmas o exclusión indirecta	Evaluación de impacto, revisión humana y corrección
Proporcionalidad	¿El beneficio esperado justifica el nivel de intrusión?	Vigilancia académica excesiva	Balance ético entre apoyo, privacidad y necesidad

4.2.2. Sesgos algorítmicos, justicia educativa y supervisión humana

Los sesgos algorítmicos en educación aparecen cuando un modelo produce resultados sistemáticamente menos favorables para determinados grupos o cuando reproduce desigualdades presentes en los datos históricos. En Learning Analytics, este riesgo es especialmente delicado porque los modelos pueden influir en alertas tempranas, asignación de apoyos, recomendaciones académicas o decisiones de gestión. Baker y Hawn (2022) revisan evidencias de sesgo algorítmico en educación y muestran que sus causas pueden ubicarse en los datos, las variables, los modelos, las interpretaciones y los contextos de aplicación.

La justicia educativa exige reconocer que los datos no son neutrales. Una variable como “número de accesos al LMS” puede reflejar compromiso, pero también desigualdad de conectividad, trabajo remunerado, responsabilidades de cuidado o barreras de accesibilidad. Si un modelo interpreta automáticamente la baja conexión como bajo compromiso, puede convertir una condición estructural en un juicio individual. Por eso, la analítica debe abrir oportunidades, no cerrar trayectorias.

La explicabilidad es una condición necesaria para la confianza. Un sistema que clasifica a un estudiante como “en riesgo” debe permitir comprender qué variables influyeron, con qué peso, con qué margen de incertidumbre y qué acción pedagógica se propone. Como plantean Kizilcec y Lee (2022), la justicia algorítmica en educación debe considerar medición, aprendizaje del modelo y acción posterior, porque el daño no ocurre solo en la predicción, sino también en la forma en que la institución responde a ella.

La supervisión humana no significa revisar manualmente cada dato, sino asegurar que ninguna decisión relevante para la trayectoria estudiantil dependa exclusivamente de una salida algorítmica. La alerta debe ser una invitación a mirar mejor, conversar, contrastar información y ofrecer apoyo. La auditoría algorítmica debe incorporarse antes, durante y después de la implementación. Antes, para revisar datos, variables, propósitos y posibles impactos; durante, para monitorear desempeño diferencial entre grupos; y después, para corregir efectos no deseados. La OECD también advierte que el sesgo algorítmico en educación puede favorecer o perjudicar poblaciones específicas y requiere pruebas, regulación y políticas de mitigación (OECD, 2023). La Figura 14 propone un ciclo de supervisión ética de modelos analíticos. El ciclo insiste en que la responsabilidad no termina cuando el modelo funciona técnicamente, sino cuando sus efectos educativos son evaluados y corregidos.

Figura 14.

Ciclo de supervisión ética de modelos analíticos



4.3. Modelo integral para implementar Learning Analytics en educación superior

Implementar Learning Analytics en educación superior requiere un modelo integral que articule diagnóstico, infraestructura, cultura de datos, formación, pilotos, evaluación y escalamiento. La experiencia internacional muestra que muchas iniciativas quedan en fase experimental porque no logran pasar del prototipo al uso institucional sostenido. Arcentales et al. (2026) advierte que la implementación institucional sigue siendo compleja y que la evidencia de impacto a gran escala continúa siendo limitada, lo cual obliga a avanzar con realismo y evaluación constante.

La primera fase del modelo es el diagnóstico institucional. Antes de seleccionar herramientas, la universidad debe preguntarse qué problemas desea atender: bajo rendimiento en asignaturas críticas, abandono temprano, escasa retroalimentación, dificultades de progresión, debilidades en la evaluación o falta de información para la planificación. Sin una pregunta educativa clara, Learning Analytics corre el riesgo de convertirse en un conjunto de dashboards visualmente atractivos, pero desconectados de decisiones reales.

La segunda fase corresponde a la infraestructura e integración de datos. Esto incluye sistemas académicos interoperables, LMS configurados adecuadamente, repositorios seguros, estándares de calidad de datos, roles de acceso y mecanismos de trazabilidad. En América Latina, los estudios sobre adopción han señalado que las limitaciones de sistemas confiables y políticas de datos pueden frenar la incorporación de Learning Analytics (Hilliger et al., 2020). La tecnología, por tanto, debe pensarse como infraestructura para acompañar, no como fin en sí misma.

La tercera fase es la construcción de cultura de datos. Esto implica formar a autoridades, docentes, tutores y equipos técnicos para interpretar información con sentido pedagógico y ético. La cultura de datos no consiste en exigir que todos sean analistas, sino en que cada actor comprenda qué puede aportar la evidencia a su responsabilidad institucional. Cuando los datos se discuten colectivamente, se reducen interpretaciones punitivas y se fortalecen decisiones compartidas.

La cuarta fase consiste en desarrollar pilotos controlados, preferentemente en asignaturas, carreras o cohortes donde exista una necesidad clara y actores dispuestos a participar. Los pilotos deben incluir criterios de éxito, protocolos de intervención, mecanismos de consentimiento, evaluación de impacto y revisión ética. Broos et al. (2020) muestran que la coordinación entre formulación de políticas e implementación es clave para escalar Learning Analytics, especialmente cuando se busca que las acciones no dependan solo de esfuerzos individuales.

La quinta fase es la evaluación de resultados y efectos no previstos. Una intervención basada en analítica debe revisar si mejoró la retroalimentación, si aumentó la participación, si permitió acompañar a estudiantes en riesgo, si redujo brechas o si generó ansiedad, estigma o resistencia. En este punto, la evaluación no puede centrarse únicamente en métricas de aprobación; debe incluir experiencia estudiantil, percepción docente, equidad, utilidad práctica y sostenibilidad. La Figura 15 resume la ruta institucional de implementación de Learning Analytics en siete fases conectadas en ciclo de mejora. El modelo propone avanzar paso a paso, sin prometer transformación inmediata, pero evitando que la prudencia se convierta en parálisis.

Figura 15.

Ruta institucional de implementación de Learning Analytics



4.3.1. Condiciones institucionales para una implementación sostenible

La sostenibilidad de Learning Analytics depende de condiciones institucionales que van más allá de la adquisición de una plataforma. La tecnología fracasa cuando no existe liderazgo, interoperabilidad, formación, confianza, claridad ética ni capacidad para convertir datos en decisiones. Una implementación sostenible requiere que la analítica se integre a la planificación académica, al aseguramiento de la calidad, al acompañamiento estudiantil y al desarrollo docente.

El liderazgo institucional es la primera condición. Las autoridades deben definir prioridades, asignar recursos, coordinar unidades y evitar que Learning Analytics quede aislado en el área tecnológica. Este liderazgo no debe ser vertical ni impositivo; necesita convocar a docentes, estudiantes, gestores, analistas, unidades de bienestar y responsables de calidad. La analítica educativa funciona mejor cuando se diseña con quienes van a interpretarla y utilizarla.

La segunda condición es la interoperabilidad. Los datos deben poder conectarse entre sistemas sin perder calidad, significado ni seguridad. Esto exige estándares, diccionarios de datos, procesos de depuración, identificación de fuentes oficiales y reglas para resolver inconsistencias. Si cada unidad maneja datos distintos sobre el mismo estudiante, la toma de decisiones se vuelve frágil y puede producir respuestas contradictorias.

La tercera condición es la formación docente y profesional. Los docentes necesitan comprender qué significan los indicadores, qué límites tienen y cómo traducirlos en retroalimentación, tutoría o rediseño didáctico. Los equipos técnicos, por su parte, requieren sensibilidad pedagógica y ética para no diseñar sistemas desconectados de la práctica educativa. Bautista et al. (2024) muestran que las percepciones de estudiantes, docentes y administradores son relevantes para integrar Learning Analytics en universidades mexicanas, especialmente cuando se busca mejorar desempeño, retroalimentación y gobernanza.

La Tabla 14 organiza condiciones para implementar Learning Analytics de manera sostenible. Su lectura permite revisar si la institución está preparada para pasar de iniciativas aisladas a una política responsable de mejora académica.

Tabla 14.

Condiciones para implementar Learning Analytics

Condición	Descripción	Responsable principal	Evidencia de avance
Liderazgo institucional	Define prioridades, recursos, responsabilidades y alcance	Rectorado, vicerrectorado académico, planificación	Política aprobada, comité activo, presupuesto asignado
Gobernanza de datos	Regula acceso, uso, seguridad, calidad y rendición de cuentas	Comité de datos, tecnología, jurídico, ética	Protocolo de datos, matriz de roles, auditorías
Interoperabilidad	Conecta sistemas académicos, LMS y servicios de apoyo	Tecnología, registros académicos, unidades académicas	Integración de bases, estándares, diccionario de datos
Formación docente	Desarrolla competencias para interpretar y actuar sobre datos	Desarrollo docente, direcciones de carrera	Programas de capacitación, comunidades de práctica
Participación estudiantil	Incorpora voz, consentimiento, transparencia y control	Bienestar, representación estudiantil, ética	Encuestas, espacios de consulta, mecanismos de reclamo
Equipos interdisciplinarios	Integra saber pedagógico, técnico, ético y de gestión	Autoridades académicas y unidades técnicas	Equipo formal, reuniones periódicas, informes integrados
Evaluación de impacto	Verifica resultados, efectos no previstos y mejoras	Calidad, investigación educativa, programas	Informes de impacto, ajustes documentados, mejora continua

4.3.2. Agenda futura de investigación y aporte del libro

La agenda futura de Learning Analytics en educación superior debe avanzar hacia preguntas más finas sobre ética, inclusión, eficacia de intervenciones, modelos explicables, gobernanza y calidad. Ya no basta con demostrar que los datos pueden predecir rendimiento o abandono; ahora es necesario investigar cuándo la predicción se transforma en apoyo, en qué condiciones mejora la experiencia educativa y qué efectos produce en estudiantes con trayectorias diversas.

Un primer vacío corresponde a la eficacia real de las intervenciones. La literatura muestra avances importantes en dashboards, alertas y retroalimentación, pero también advierte que sus efectos no siempre son robustos ni generalizables. Hernández et al. (2025) señalan que aún existen limitaciones en la comprensión teórica de los factores asociados a resultados de aprendizaje. La investigación futura debe diferenciar entre observar datos, interpretar datos y mejorar efectivamente las condiciones de aprendizaje.

Un segundo desafío se ubica en la ética aplicada. La privacidad, el consentimiento y la transparencia no pueden tratarse como anexos de proyectos tecnológicos. Heiser et al. (2026) muestran que la comunicación ambigua sobre Learning Analytics puede reforzar asimetrías de poder y debilitar el consentimiento informado. Por ello, futuras investigaciones deben estudiar cómo comunicar la analítica de manera comprensible, participativa y respetuosa de la agencia estudiantil.

Un tercer campo de investigación se relaciona con inclusión y justicia educativa, los modelos deben evaluarse no solo por precisión global, sino por desempeño diferencial entre grupos, contextos y condiciones de acceso; esto implica estudiar sesgos, accesibilidad digital, brechas de conectividad, diversidad lingüística, discapacidad, trayectorias no tradicionales y experiencias de estudiantes trabajadores o cuidadores (Cano-Zambrano et al., 2026). Learning Analytics será verdaderamente valioso si ayuda a ver desigualdades que antes permanecían ocultas.

Un cuarto eje corresponde a la gobernanza y sostenibilidad institucional. Se requiere más investigación sobre modelos de madurez, estructuras de decisión,

comités de datos, roles profesionales, políticas institucionales y evaluación de impacto. El aporte de este libro consiste precisamente en articular Learning Analytics con rendimiento académico, trayectorias estudiantiles, gestión universitaria, ética y gobernanza, evitando dos extremos: el entusiasmo tecnodeterminista y el rechazo simplista de los datos.

La Figura 16 cierra el capítulo con una agenda futura de Learning Analytics en educación superior. Su sentido final es prudente y esperanzador: los datos pueden ayudar a construir una universidad más inteligente, pero solo si permanecen al servicio de una educación más humana, justa y responsable.

Figura 16.

Agenda futura de Learning Analytics en educación superior



Referencias Bibliográficas

- Afzaal, M., y Nouri, J. (2024). A Systematic Review of Software for Learning Analytics in Higher Education. *International Journal of Emerging Technologies in Learning (IJET)*, 19(07), 17–43. <https://doi.org/10.3991/ijet.v19i07.50313>
- Alfredo, R., Echeverria, V., Jin, Y., Yan, L., Swiecki, Z., Gašević, D., y Martinez-Maldonado, R. (2024). Human-Centred Learning Analytics and AI in Education: A Systematic Literature Review. *Computers and Education: Artificial Intelligence*, 6, 100215. <https://doi.org/10.1016/j.caeai.2024.100215>
- Al-Zahrani, A., y Alasmari, T. (2023). Learning Analytics for Data-Driven Decision Making: Enhancing Instructional Personalization and Student Engagement in Online Higher Education. *International Journal of Online Pedagogy and Course Design*, 13, 1–18. <https://doi.org/10.4018/IJOPCD.331751>
- Arcentales-Matute, J. P., Briones-García, N. M., Delgado-Mora, M. C., Domínguez-Chancay, D. S., García-Bucheli, C. C., Intriago-Giler, L. P., Intriago-Intriago, E. A., Leonidas, R., Segovia-García, M. S., y Velásquez-Olton, M. Y. (2026). Educar en Tiempos de Transformación: Innovación Pedagógica y Compromiso Social. En *Oriente-Manabí Editorial*. Oriente-Manabí Editorial. <https://doi.org/10.63618/omeditorial/l18>
- Baker, R. S., y Hawn, A. (2022). Algorithmic Bias in Education. *International Journal of Artificial Intelligence in Education*, 32(4), 1052–1092. <https://doi.org/10.1007/s40593-021-00285-9>

Banihashem, S. K., Noroozi, O., van Ginkel, S., Macfadyen, L. P., y Biemans, H.

J. A. (2022). A systematic review of the role of learning analytics in enhancing feedback practices in higher education. *Educational Research Review*, 37, 100489. <https://doi.org/10.1016/j.edurev.2022.100489>

Bergdahl, N., Bond, M., Sjöberg, J., Dougherty, M., y Oxley, E. (2024). Unpacking student engagement in higher education learning analytics: A systematic review. *International Journal of Educational Technology in Higher Education*, 21(1), 63. <https://doi.org/10.1186/s41239-024-00493-y>

Broos, T., Hilliger, I., Pérez-Sanagustín, M., Htun, N.-N., Millecamp, M., Pesántez-Cabrera, P., Solano-Quinde, L., Siguenza-Guzman, L., Zuñiga-Prieto, M., Verbert, K., y De Laet, T. (2020). Coordinating learning analytics policymaking and implementation at scale. *British Journal of Educational Technology*, 51(4), 938–954. <https://doi.org/10.1111/bjet.12934>

Cano-Zambrano, M. E., Cedeño-Montesdeoca, S. M., Cool-Vergara, E. N., Ganchozo-Loor, M. V., Holguín-Intriago, A. I., Mendoza-Briones, U. O., Mendoza-Pérez, A. V., Párraga-Gallardo, J. L., Sornoza-Bravo, J. C., y Zambrano-Domínguez, V. I. (2026). Reimaginar la educación pedagogía, innovación y sentido humano en la escuela contemporánea. En *Oriente-Manabí Editorial*. Oriente-Manabí Editorial. <https://doi.org/10.63618/omeditorial/l19>

Dai, W., Lin, J., Jin, F. J.-Y., Tsai, Y.-S., Srivastava, N., Bodic, P. L., Gašević, D., y Chen, G. (2025). Learning Analytics for Early Identification of At-Risk Students and Feedback Intervention. *Journal of Learning Analytics*, 12(3), 102–125. <https://doi.org/10.18608/jla.2025.8735>

- De Oliveira, C. F., Sobral, S. R., Ferreira, M. J., y Moreira, F. (2021). How Does Learning Analytics Contribute to Prevent Students' Dropout in Higher Education: A Systematic Literature Review. *Big Data and Cognitive Computing*, 5(4). <https://doi.org/10.3390/bdcc5040064>
- De Silva, L. M. H., Chounta, I.-A., Rodríguez-Triana, M. J., Roa, E. R., Gramberg, A., y Valk, A. (2022). Toward an Institutional Analytics Agenda for Addressing Student Dropout in Higher Education: An Academic Stakeholders' Perspective. *Journal of Learning Analytics*, 9(2), 179–201. <https://doi.org/10.18608/jla.2022.7507>
- De Vreugd, L., Van Leeuwen, A., Jansen, R., y Van Der Schaaf, M. (2024). Learning Analytics Dashboard Design and Evaluation to Support Student Self-Regulation of Study Behaviour. *Journal of Learning Analytics*, 11(3), 249–262. <https://doi.org/10.18608/jla.2024.8529>
- De Witte, K., y Chénier, M.-A. (2023). Learning Analytics in Education for the Twenty-First Century. En E. Bertoni, M. Fontana, L. Gabrielli, S. Signorelli, y M. Vespe (Eds.), *Handbook of Computational Social Science for Policy* (pp. 305–326). Springer International Publishing. https://doi.org/10.1007/978-3-031-16624-2_16
- Dixon, N., Howe, R., y Richter, U. M. (2025). Exploring learning analytics practices and their benefits through the lens of three case studies in UK higher education. *Research in Learning Technology*, 33. <https://doi.org/10.25304/rlt.v33.3127>
- Drăgoi, M.-V., Puiu, R.-A., Petrea, G., Cristoiu, C. A., y Dumitrescu, C.-I. (2026). Willingness to Allow Educational Data Use for Learning Analytics in Higher

Education: Trust and Governance Predictors: An Exploratory Study.

Education Sciences, 16(4). <https://doi.org/10.3390/educsci16040637>

Du Plooy, E., Casteleijn, D., y Franzsen, D. (2024). Personalized adaptive learning in higher education: A scoping review of key characteristics and impact on academic performance and engagement. *Heliyon*, 10(21). <https://doi.org/10.1016/j.heliyon.2024.e39630>

Fazil, M., Rísquez, A., y Halpin, C. (2024). A Novel Deep Learning Model for Student Performance Prediction Using Engagement Data. *Journal of Learning Analytics*, 11(2), 23–41. <https://doi.org/10.18608/jla.2024.7985>

Foster, E., y Siddle, R. (2020). The effectiveness of learning analytics for identifying at-risk students in higher education. *Assessment & Evaluation in Higher Education*, 45(6), 842–854. <https://doi.org/10.1080/02602938.2019.1682118>

Freitas, E., Fonseca, F., Garcia, V., Falcão, T. P., Marques, E., Gašević, D., y Mello, R. F. (2024). MMALA: Developing and Evaluating a Maturity Model for Adopting Learning Analytics. *Journal of Learning Analytics*, 11(1), 67–86. <https://doi.org/10.18608/jla.2024.8099>

García-García, F. J., Gómez-Núñez, M. I., y Molla-Esparza, C. (2026). Applications of learning analytics in the study of academic performance in higher education: A meta-review with an educational perspective. *Higher Education*. <https://doi.org/10.1007/s10734-026-01709-y>

Godínez, T. B., Garza, G. C., Mora, R. P., Ceballos, H. G., Luz, V. L. de la, Moreno-Salinas, J. G., Zavala-Sierra, I. R., Santos-Solórzano, R., Arellano, C. I. M., y Sánchez-Mendiola, M. (2024). Perspectives and Opportunities for Learning Analytics Integration: A Qualitative Study in

Mexican Universities. *Journal of Learning Analytics*, 11(1), 49–66.

<https://doi.org/10.18608/jla.2024.8125>

Guzmán-Valenzuela, C., Gómez-González, C., Rojas-Murphy Tagle, A., y Lorca-Vyhmeister, A. (2021a). Learning analytics in higher education: A preponderance of analytics but very little learning? *International Journal of Educational Technology in Higher Education*, 18(1), 23.
<https://doi.org/10.1186/s41239-021-00258-x>

Guzmán-Valenzuela, C., Gómez-González, C., Rojas-Murphy Tagle, A., y Lorca-Vyhmeister, A. (2021b). Learning analytics in higher education: A preponderance of analytics but very little learning? *International Journal of Educational Technology in Higher Education*, 18(1), 23.
<https://doi.org/10.1186/s41239-021-00258-x>

Hakimi, L., Eynon, R., y Murphy, V. A. (2021). The Ethics of Using Digital Trace Data in Education: A Thematic Review of the Research Landscape. *Review of Educational Research*, 91(5), 671–717.
<https://doi.org/10.3102/00346543211020116>

Heiser, R., Underhill, G., y Stritto, M. E. D. (2026). Power, Privacy, and Transparency in Communicating Learning Analytics in Higher Education: A Critical Discourse Analysis. *American Journal of Qualitative Research*, 10(1), 246–265. <https://doi.org/10.29333/ajqr/17463>

Hernández-Campos, M., Gonzalez-Torres, A., y García-Peñalvo, F. J. (2025). Learning Outcomes Evaluation Through Learning Analytics Systems in Higher Education: A Systematic Literature Review. *Sage Open*, 15(3), 21582440251347374. <https://doi.org/10.1177/21582440251347374>

- Hilliger, I., Ortiz-Rojas, M., Pesántez-Cabrera, P., Scheihing, E., Tsai, Y.-S., Muñoz-Merino, P. J., Broos, T., Whitelock-Wainwright, A., Gašević, D., y Pérez-Sanagustín, M. (2020). Towards learning analytics adoption: A mixed methods study of data-related practices and policies in Latin American universities. *British Journal of Educational Technology*, 51(4), 915–937. <https://doi.org/10.1111/bjet.12933>
- Ifenthaler, D., y Yau, J. Y.-K. (2020). Utilising learning analytics to support study success in higher education: A systematic review. *Educational Technology Research and Development*, 68(4), 1961–1990. <https://doi.org/10.1007/s11423-020-09788-z>
- Jones, K. M. L. (2019). 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*, 16(1), 24. <https://doi.org/10.1186/s41239-019-0155-0>
- Kaliisa, R., Misiejuk, K., López-Pernas, S., Khalil, M., y Saqr, M. (2024). Have Learning Analytics Dashboards Lived Up to the Hype? A Systematic Review of Impact on Students' Achievement, Motivation, Participation and Attitude. *Proceedings of the 14th Learning Analytics and Knowledge Conference, LAK '24*, 295–304. <https://doi.org/10.1145/3636555.3636884>
- Khalil, M., Prinsloo, P., y Slade, S. (2023). The use and application of learning theory in learning analytics: A scoping review. *Journal of Computing in Higher Education*, 35(3), 573–594. <https://doi.org/10.1007/s12528-022-09340-3>
- Khosravi, H., Shibani, A., Jovanovic, J., Pardos, Z. A., y Yan, L. (2025). Generative AI and Learning Analytics: Pushing Boundaries, Preserving

<https://doi.org/10.18608/jla.2025.8961>

Kizilcec, R. F., y Lee, H. (2022). Algorithmic fairness in education. En *The Ethics of Artificial Intelligence in Education*. Routledge.

<https://www.taylorfrancis.com/chapters/edit/10.4324/9780429329067-10/algorithmic-fairness-education-ren%C3%A9-kizilcec-hansol-lee>

Korir, M., Slade, S., Holmes, W., Hélot, Y., y Rienties, B. (2023). Investigating the dimensions of students' privacy concern in the collection, use and sharing of data for learning analytics. *Computers in Human Behavior Reports*, 9, 100262. <https://doi.org/10.1016/j.chbr.2022.100262>

Lang, C., Siemens, G., Wise, A. F., Gašević, D., y Merceron, A. (2022). *Handbook of Learning Analytics* (Second edition). <https://doi.org/10.18608/hla22>

Lemay, D. J., Baek, C., y Doleck, T. (2021). Comparison of learning analytics and educational data mining: A topic modeling approach. *Computers and Education: Artificial Intelligence*, 2, 100016. <https://doi.org/10.1016/j.caeai.2021.100016>

Molla-Esparza, C., Gómez-Núñez, M. I., y García-García, F. J. (2025). Applications of learning analytics in the study of academic performance in higher education: A pilot-tested meta-review protocol. *International Journal of Educational Research Open*, 8, 100433. <https://doi.org/10.1016/j.ijedro.2024.100433>

Namoun, A., y Alshanqiti, A. (2020). Predicting Student Performance Using Data Mining and Learning Analytics Techniques: A Systematic Literature Review. *Applied Sciences*, 11(1). <https://doi.org/10.3390/app11010237>

OECD. (2023). *OECD Digital Education Outlook 2023: Towards an Effective Digital Education Ecosystem*. OECD Publishing.

<https://doi.org/https://doi.org/10.1787/c74f03de-en>

Pan, Z., Biegley, L., Taylor, A., y Zheng, H. (2024). A Systematic Review of Learning Analytics: Incorporated Instructional Interventions on Learning Management Systems. *Journal of Learning Analytics*, 11(2), 52–72.

<https://doi.org/10.18608/jla.2023.8093>

Pargman, T. C., y McGrath, C. (2021). Mapping the Ethics of Learning Analytics in Higher Education: A Systematic Literature Review of Empirical Research. *Journal of Learning Analytics*, 8(2), 123–139.

<https://doi.org/10.18608/jla.2021.1>

Rienties, B., Tempelaar, D., Nguyen, Q., y Rogaten, J. (2024). The use of data analytics to support the development of assessment practices in higher education. En *Research Handbook on Innovations in Assessment and Feedback in Higher Education* (pp. 194–209). Edward Elgar Publishing.

<https://www.elgaronline.com/edcollchap/book/9781800881600/chapter11.xml>

Riestra-González, M., Paule-Ruíz, M. del P., y Ortin, F. (2021). Massive LMS log data analysis for the early prediction of course-agnostic student performance. *Computers & Education*, 163, 104108.

<https://doi.org/10.1016/j.compedu.2020.104108>

Romero, C., y Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *WIREs Data Mining and Knowledge Discovery*, 10(3), e1355. <https://doi.org/10.1002/widm.1355>

- Saqr, M., López-Pernas, S., Helske, S., y Hrastinski, S. (2023). The longitudinal association between engagement and achievement varies by time, students' profiles, and achievement state: A full program study. *Computers & Education*, 199, 104787. <https://doi.org/10.1016/j.compedu.2023.104787>
- Soffer, T., y Cohen, A. (2024). Privacy versus pedagogy – students' perceptions of using learning analytics in higher education. *Australasian Journal of Educational Technology*, 40(5), 14–30. <https://doi.org/10.14742/ajet.9130>
- Tsai, Y.-S., Whitelock-Wainwright, A., y Gašević, D. (2021). More Than Figures on Your Laptop: (Dis)trustful Implementation of Learning Analytics. *Journal of Learning Analytics*, 8(3), 81–100. <https://doi.org/10.18608/jla.2021.7379>
- Wasson, B., Giannakos, M., Blikstad-Balas, M., Uppstad, P. H., Langford, M., y Bøhn, E. D. (2024). Implementing Learning Analytics in Norway: Four Central Dilemmas. *Journal of Learning Analytics*, 11(2), 268–280. <https://doi.org/10.18608/jla.2024.8241>
- Weidlich, J., Fink, A., Frey, A., Jivet, I., Gombert, S., Menzel, L., Giorgashvili, T., Yau, J., y Drachsler, H. (2025). Highly informative feedback using learning analytics: How feedback literacy moderates student perceptions of feedback. *International Journal of Educational Technology in Higher Education*, 22(1), 43. <https://doi.org/10.1186/s41239-025-00539-9>

Resumen

El libro Educación basada en datos. Learning Analytics para mejorar el rendimiento académico y la gestión universitaria analiza el papel de los datos educativos en la transformación responsable de la educación superior. Su propósito es ofrecer una comprensión rigurosa y pedagógicamente sensible sobre cómo Learning Analytics puede contribuir al seguimiento del aprendizaje, la detección temprana de riesgos académicos, la mejora del rendimiento estudiantil y el fortalecimiento de la toma de decisiones institucionales. La obra parte de la premisa de que los datos no poseen valor educativo por sí mismos, sino cuando son interpretados desde criterios pedagógicos, éticos y contextuales. A lo largo de sus capítulos, se examinan los fundamentos conceptuales de la educación basada en datos, sus aplicaciones en el acompañamiento académico, su aporte a la gestión universitaria y los desafíos asociados a la privacidad, la transparencia, la gobernanza y la responsabilidad institucional. El enfoque del libro rechaza una visión tecnocrática de la analítica educativa y propone una integración equilibrada entre tecnología, pedagogía, gestión y sentido humano. En este marco, Learning Analytics se concibe como una herramienta estratégica para mejorar la calidad, la inclusión y la permanencia estudiantil.

Palabras Clave: Learning Analytics; educación superior; rendimiento académico; gestión universitaria; ética de datos.

Abstract

The book Data-Based Education. Learning Analytics to Improve Academic Performance and University Management analyzes the role of educational data in the responsible transformation of higher education. Its purpose is to provide a rigorous and pedagogically sensitive understanding of how Learning Analytics can support learning monitoring, early detection of academic risks, improvement of student performance, and strengthening of institutional decision-making. The work is based on the premise that data do not have educational value by themselves, but only when interpreted through pedagogical, ethical, and contextual criteria. Throughout its chapters, the book examines the conceptual foundations of data-based education, its applications in academic support, its contribution to university management, and the challenges related to privacy, transparency, governance, and institutional responsibility. The approach rejects a technocratic view of educational analytics and proposes a balanced integration of technology, pedagogy, management, and human meaning. Within this framework, Learning Analytics is conceived as a strategic tool to improve quality, inclusion, and student retention, while promoting more informed, reflective, and responsible universities

Keywords: Learning Analytics; higher education; academic performance; university management; data ethics.

ISBN: 978-9907-9567-0-2



9 789907 956702

Descubra como el uso inteligente de los datos puede transformar la educación universitaria. En este libro exploramos cómo las analíticas de aprendizaje pueden ayudar a mejorar el rendimiento académico, optimizar la gestión universitaria, personalizar la enseñanza y tomar decisiones más informadas. A través de ejemplos prácticos y herramientas innovadoras.



OM
EDITORIAL