



EDITORIAL
UNIÓN CIENTÍFICA



LEARNING ANALYTICS

para la personalización del aprendizaje
en entornos virtuales de **educación superior**

Autores

- Verónica Teresa Veloz Segura
- Elizabeth Alexandra Veloz Segura
- Javier Alonso Veloz Segura
- Liana Fuentes Seisdedos



E D I T O R I A L
UNIÓN CIENTÍFICA

Editorial Unión Científica, EUC

Copyright © Editorial Unión Científica, EUC

Copyright del texto © 2026 de los autores

<https://libros.editorialunioncientifica.com/>

info@editorialuc.com

WhatsApp +593 98 334 4363

Licencia no comercial



TÍTULO: Learning Analytics para la personalización del aprendizaje en entornos virtuales de educación superior

Learning Analytics for personalizing learning in virtual higher education environments

AUTORES

Verónica Teresa Veloz Segura¹

<https://orcid.org/0000-0002-1440-0115>

correo vveloz@ueb.edu.ec

Elizabeth Alexandra Veloz Segura¹

<https://orcid.org/0000-0003-4562-7619>

correo eveloz@ueb.edu.ec

Javier Alonso Veloz Segura²

<https://orcid.org/0009-0009-0396-2487>

correo jveloz@ueb.edu.ec

Liana Fuentes Seisdedos¹

<https://orcid.org/0000-0002-6702-6155>

correo lfuentes@ueb.edu.ec

¹ Facultad de Ciencias de la Educación, Sociales, Filosóficas y Humanísticas. Universidad Estatal de Bolívar. Guaranda, Ecuador. ROR: <https://ror.org/005cgg117>

² Facultad de Jurisprudencia, Ciencias Sociales y Políticas. Universidad Estatal de Bolívar. Guaranda, Ecuador. ROR: <https://ror.org/005cgg117>

CÓMO CITAR

Veloz Segura, V. T., Veloz Segura, E. A., Veloz Segura, J. A., & Fuentes Seisdedos, L. (2026). Learning Analytics para la personalización del aprendizaje en entornos virtuales de educación superior. Editorial Unión Científica.

<https://doi.org/10.63804/libroseuc.6>

Editorial Unión científica, EUC.

EDITOR JEFE: Carlos Luis Vásquez Freytez. Universidad Técnica de Ambato, UTA. Ecuador. **ORCID:** <https://orcid.org/0000-0002-8214-3632>

CORRECCIÓN ESTILO: Gabriela Otilia Jácome Benavides. Fundación Río Verde Ecuador Emprende. Ecuador.

PÁGINAS: 106.

CIUDAD: Ambato

PROCESO DE REVISIÓN: toda la obra ha sido revisada por expertos externos bajo la modalidad *Double blind*.

ISBN: 978-9907-9552-3-1.

DOI: <https://doi.org/10.63804/libroseuc.6>

PRIMERA VERSIÓN DISPONIBLE EN LÍNEA: junio de 2026.

Clasificación Dewey Decimal (DDC):

378 Educación superior.

Clasificación THEMA:

J Sociedad y ciencias sociales.

JN Educación.

JNM Enseñanza superior, estudios avanzados

JNMT Formación del profesorado.

ISBN: 978-9907-9552-3-1



COMITÉ CIENTÍFICO

[Cristian Vacacela Gómez](#), PhD. INFN-Laboratori Nazionali di Frascati, Frascati, Italia.

[Óscar Alí Corona Salazar](#), PhD. Pontificia Universidad Católica Madre y Maestra, PUCMM. Campus Santiago. República Dominicana.

[Miguel Israel Bennasar García](#), PhD. Instituto Superior de Formación Docente Salomé Ureña, ISFODASU. República Dominicana.

[Helen Goitia Semeco](#), PhD. Universidad Nacional de La Plata, UNLP. Argentina.

[Diana Carolina Coello Fiallos](#), PhD. Escuela Superior Politécnica de Chimborazo, ESPOCH. Ecuador.

[Daniel Arias Toro](#), PhD. Universidad Técnica de Babahoyo, UTB. Ecuador.

[Ruth Mariela Álvarez Escalona](#), PhD. Universidad Experimental del Táchira, UNET. Venezuela. Profesor de Química, Bioquímica-Ingeniería Ambiental-Catálisis.

[Paúl Miño Armijos](#), MSc. Universidad Católica de Cuenca, UCACUE. Ecuador. Máster en Intervención Psicosocial y Comunitaria.

[María Raquel González Legendre](#), MSc. CEO Ciencia por la verdad. Ecuador.

Learning Analytics para la personalización del aprendizaje en entornos virtuales de educación superior

Glosario de términos

Academic Analytics: uso de datos académicos a nivel institucional para apoyar decisiones de gestión, planificación, políticas universitarias y mejora de programas.

Alerta temprana: señal generada a partir de datos educativos que permite identificar oportunamente posibles dificultades académicas y activar acciones de acompañamiento.

Calidad de los datos: condición que permite que los datos sean completos, actualizados, consistentes, pertinentes y confiables para el análisis educativo.

Compromiso estudiantil: grado de vinculación del estudiante con su proceso de aprendizaje, visible en su regularidad, participación, cumplimiento de actividades y persistencia en el curso.

Cultura institucional basada en evidencia: forma de gestión universitaria que utiliza datos, análisis y reflexión colectiva para mejorar la enseñanza, el aprendizaje y la toma de decisiones.

Dashboard educativo: tablero visual que presenta indicadores relevantes para que docentes, tutores o gestores puedan tomar decisiones académicas.

Datos educativos: información generada durante el proceso formativo en entornos digitales, como accesos al aula virtual, entregas de tareas, calificaciones, participación en foros, uso de recursos, mensajes y registros de tutoría.

Diseño instruccional basado en datos: uso de evidencias educativas para mejorar la estructura del curso, las actividades, los recursos, las evaluaciones y los momentos de retroalimentación.

Educational Data Mining: campo relacionado con la minería de datos educativos, orientado a descubrir patrones en grandes volúmenes de información académica.

Entorno Virtual de Aprendizaje - EVA: espacio digital organizado para desarrollar actividades, recursos, comunicación, evaluación y seguimiento académico. No debe entenderse solo como un repositorio de archivos, sino como un ambiente pedagógico.

Ética de datos: uso responsable, transparente y justo de la información educativa, evitando vigilancia, etiquetamiento o decisiones automáticas injustas.

Evaluación formativa: evaluación orientada a mejorar el aprendizaje durante el desarrollo del curso, no solo a asignar una calificación final.

Gobernanza de datos: conjunto de políticas, normas, roles y responsabilidades que regulan la recolección, uso, protección, interpretación y evaluación de los datos educativos.

Indicadores académicos: señales o métricas que permiten observar aspectos del proceso educativo, como desempeño, avance, participación, cumplimiento, interacción y riesgo académico.

Justicia algorítmica: principio que busca que los modelos basados en datos no discriminen ni perjudiquen a estudiantes por sus condiciones sociales, tecnológicas o académicas.

Learning Analytics: proceso de recopilación, análisis e interpretación de datos educativos para comprender y mejorar el aprendizaje, la participación, el rendimiento y la permanencia estudiantil. En el libro se plantea como una estrategia para observar trayectorias, detectar necesidades, prever riesgos y orientar apoyos pedagógicos.

Modelo descriptivo: análisis que permite observar lo que ocurre en el proceso educativo, como accesos, participación, avances, entregas o resultados parciales.

Modelo predictivo: modelo que utiliza datos para anticipar posibles situaciones futuras, como bajo rendimiento, abandono o necesidad de apoyo.

Modelo prescriptivo: modelo que, además de identificar una situación, sugiere acciones posibles, como recomendar recursos, tutorías o actividades de refuerzo.

Participación estudiantil: interacción del estudiante con el curso, los docentes, los compañeros, los recursos y las actividades dentro del entorno virtual.

Personalización del aprendizaje: estrategia que permite ajustar recursos, actividades, retroalimentación o tutorías según las necesidades, desempeño, ritmo y trayectoria del estudiante.

Privacidad de datos: protección de la información personal y académica del estudiante frente a accesos indebidos o usos no autorizados.

Rendimiento académico: resultado obtenido por el estudiante en tareas, pruebas, evaluaciones, proyectos u otras actividades de valoración.

Retroalimentación personalizada: orientación específica que recibe el estudiante de acuerdo con sus avances, errores, resultados o necesidades particulares.

Riesgo académico: situación en la que un estudiante presenta señales de posible bajo desempeño, rezago, desconexión, inactividad o abandono.

Sesgo algorítmico: riesgo de que un sistema analítico reproduzca desigualdades o genere interpretaciones injustas sobre ciertos estudiantes.

Sistema de recomendación: herramienta que propone recursos, actividades, rutas de aprendizaje o apoyos según las necesidades detectadas en el estudiante.

Tecno centrismo: visión limitada que considera que la tecnología por sí sola mejora la educación, sin atender la pedagogía, el contexto, la ética y la mediación docente.

Transformación digital educativa: cambio institucional que integra tecnología, pedagogía, cultura organizacional y toma de decisiones basada en datos para mejorar la educación.

Tutoría académica apoyada en datos: proceso de acompañamiento que utiliza evidencias analíticas para orientar al estudiante, identificar dificultades y dar seguimiento a su trayectoria académica.

Validez del indicador: grado en que un indicador realmente mide lo que pretende observar. Por ejemplo, el tiempo de conexión no siempre equivale a aprendizaje.

Índice

Portada	i
GLOSARIO DE TÉRMINOS	vii
RESUMEN	12
ABSTRACT	13
PRÓLOGO	14
SECCIÓN 1	16
Educación Superior virtual y personalización del aprendizaje	16
Transformación digital de la Educación Superior	16
Entornos virtuales de aprendizaje en contextos universitarios	19
Personalización del aprendizaje: fundamentos pedagógicos	23
Personalización en la Educación Superior virtual	26
Brechas, permanencia y éxito académico en la educación virtual	29
SECCIÓN 2	33
Fundamentos de Learning Analytics en contextos universitarios	33
Conceptualización de Learning Analytics	33
Evolución histórica y tendencias internacionales	35
Learning Analytics, Educational Data Mining y Academic Analytics	37
Ciclo de vida de Learning Analytics	40
Actores involucrados en Learning Analytics	42
Arquitecturas tecnológicas para Learning Analytics	45
SECCIÓN 3	49
Datos educativos, indicadores académicos y perfilado del estudiante	49
Naturaleza de los datos educativos	49
Fuentes de datos en entornos virtuales universitarios	52
Indicadores académicos para Learning Analytics	55
Indicadores de compromiso y participación estudiantil	58
Perfilado del estudiante en ambientes virtuales	60

Segmentación de estudiantes mediante analíticas	63
Calidad, validez y gobernanza de los datos educativos	65
SECCIÓN 4	68
Modelos de personalización del aprendizaje basados en analíticas	68
Modelos descriptivos para la personalización	68
Modelos predictivos de desempeño y riesgo académico	70
Modelos prescriptivos y sistemas de recomendación	71
Personalización de contenidos y recursos educativos	73
Personalización de la evaluación y retroalimentación	75
Tutoría académica apoyada en Learning Analytics	77
Diseño instruccional basado en datos	79
Integración de inteligencia artificial en la personalización	81
SECCIÓN 5	84
Impacto académico, ética de datos y desafíos institucionales	84
Impacto académico de Learning Analytics	84
Evaluación de intervenciones basadas en analíticas	85
Ética de datos en Learning Analytics	87
Sesgos, equidad y justicia algorítmica	89
Gobernanza institucional de Learning Analytics	91
Cultura institucional basada en evidencia	93
Desafíos técnicos, pedagógicos y organizacionales	95
Perspectivas futuras de Learning Analytics	96
CONCLUSIONES	100

Resumen

Esta obra examina el potencial de Learning Analytics como estrategia para la personalización del aprendizaje en la educación superior virtual, superando el enfoque tecnocéntrico. A través de una articulación teórica y metodológica, se analiza cómo las huellas digitales generadas por los estudiantes en los entornos virtuales pueden transformarse en evidencias pedagógicas interpretables para optimizar las trayectorias formativas al mismo tiempo que fortalece la permanencia estudiantil y mitiga los riesgos de abandono. El texto establece distinciones conceptuales importantes entre la analítica del aprendizaje, la minería de datos educativos (Educational Data Mining) y la analítica académica (Academic Analytics), delimitando el alcance operativo de cada disciplina dentro de la gestión universitaria. Asimismo, se profundiza en las dimensiones que sustentan el ciclo de vida de los datos, desde las fuentes de recopilación e interoperabilidad tecnológica hasta la construcción de indicadores válidos de compromiso, regularidad y desempeño académico. Mediante un abordaje integral, el libro describe la implementación de modelos descriptivos, predictivos y prescriptivos, detallando el funcionamiento de los sistemas de recomendación adaptativa, las tutorías académicas automatizadas y el diseño instruccional fundamentado en la evidencia de datos. Más allá de los componentes computacionales y algorítmicos, los autores priorizan de manera transversal la dimensión ética, la transparencia, la gobernanza institucional y la justicia algorítmica, advirtiendo sobre los peligros del control desproporcionado, los sesgos automatizados y el etiquetamiento estigmatizante del estudiante. En conclusión, la obra se propone como un marco de referencia para docentes, investigadores y gestores universitarios comprometidos con la transformación digital, demostrando que la analítica del aprendizaje alcanza su verdadero valor únicamente cuando se sitúa al servicio del desarrollo humano, la equidad socioeducativa y la mejora continua de la calidad académica en los entornos virtuales.

Palabras clave: analítica del aprendizaje; educación superior; entornos virtuales; ética de datos; personalización del aprendizaje.

Abstract

This work examines the potential of Learning Analytics as a strategy for personalizing learning in virtual higher education, moving beyond a purely technocentric approach. Through a theoretical and methodological articulation, it analyzes how the digital traces generated by students in virtual learning environments can be transformed into interpretable pedagogical evidence to optimize learning pathways, strengthen student retention, and mitigate dropout risks. The text establishes important conceptual distinctions among Learning Analytics, Educational Data Mining (EDM), and Academic Analytics, defining the operational scope of each discipline within the context of university management. It also provides an in-depth examination of the dimensions that underpin the data lifecycle, ranging from data collection sources and technological interoperability to the development of valid indicators of student engagement, regularity, and academic performance. Through a comprehensive approach, the book describes the implementation of descriptive, predictive, and prescriptive models, detailing the operation of adaptive recommendation systems, automated academic tutoring, and evidence-based instructional design. Beyond computational and algorithmic components, the authors place strong emphasis on ethical considerations, transparency, institutional governance, and algorithmic fairness, warning against the risks of excessive surveillance, automated bias, and the stigmatizing labeling of students. In conclusion, the work is proposed as a reference framework for educators, researchers, and university administrators committed to digital transformation. It demonstrates that Learning Analytics achieves its true value only when it is placed at the service of human development, socio-educational equity, and the continuous improvement of academic quality in virtual learning environments.

Keywords: learning analytics; higher education; virtual learning environments; data ethics; personalized learning.

Prólogo

La Educación Superior se encuentra actualmente en transformación; misma que no puede ser entendida únicamente a partir de la incorporación de plataformas, de repositorios digitales, de herramientas de comunicación en línea, etc. El cambio más significativo se produce en la manera en que las instituciones entienden, acompañan y evalúan las trayectorias de aprendizaje de sus estudiantes en los entornos virtuales, en los que un porcentaje elevado de actividad académica queda registrada en sistemas digitales, las universidades obtienen nuevas posibilidades para observar y documentarse sobre patrones de participación, desempeño, interacción y permanencia.

Esta posibilidad no es suficiente para entender la mejora educativa; requiere interpretación pedagógica, criterios éticos y capacidad institucional suficientes para convertir los datos en decisiones responsables. Este libro se sitúa precisamente en este punto de encuentro entre educación, tecnología, analítica de datos y gestión universitaria. No se busca ofrecer Learning Analytics como una herramienta capaz de dar respuesta autónomamente a los problemas de la educación virtual, sino que se trata de reflexionar acerca de su potencial como estrategia de personalización del aprendizaje en el contexto de la Educación Superior. La obra asume que los datos educativos pueden servir para detectar necesidades, prever riesgos, orientar tutorías, optimizar recursos e incluso rediseñar experiencias de enseñanza; a su vez, advierte de que los datos son, por su naturaleza, parciales, quebradizos y frágiles, de manera que su uso requiere un uso cuidadoso, transparente y supervisado.

Ofrece una mirada amplia y crítica a quiénes participan de la construcción de universidades digitales más justas, más pertinentes y más sostenibles. Su aportación está en articular fundamentos pedagógicos, indicadores, modelos de personalización, sistemas de recomendación, tutorización a partir de evidencias, evaluación de impacto, ética y gobernanza. Su mayor valor está en la articulación: demostrar que Learning Analytics puede contribuir a la personalización del aprendizaje solo si se integra en un proyecto académico centrado en el estudiante, orientado a la equidad y comprometido con la mejora continua.

Introducción

La expansión de la Educación Superior ha modificado las condiciones en las cuales las universidades implementan y evalúan los procesos formativos en los entornos digitales, la acción docente va dejando huellas que nos permiten observar aspectos que no eran fáciles recoger: acceso a los recursos, participación a las actividades, tiempos de conexión, entregas, rendimiento ante las evaluaciones, intervenciones en foros, uso de materiales, trayectorias de avance en el marco de un curso.

Learning Analytics aparece en este escenario como una propuesta dirigida a la recopilación, el análisis y la interpretación de datos para conseguir una comprensión y una mejora de los elementos del aprendizaje y de los entornos del mismo. Su importancia en la Educación Superior está asociada a la necesidad de dar visibilidad a patrones de participación, rendimiento y riesgo académico que suelen ser invisibles en grupos amplios. La analítica del aprendizaje puede ser un apoyo para monitorizar, diagnosticar, predecir, recomendar e intervenir, pero esta función depende de los datos y no como información automática de éxito o fracaso.

La adaptación del aprendizaje es el eje pedagógico del presente texto, personalizar no significa sustituir al docente por un sistema automatizado, ni fragmentar la experiencia universitaria como si de trayectorias individuales intrascendentes se tratase. Significa visibilizar diferencias relevantes entre estudiantes y definir apoyos, recursos, actividades, retroalimentaciones o tutorías que permitan dar respuesta a las necesidades académicas que vayan emergiendo.

El presente texto se centra en el tratamiento de datos educativos para describir trayectorias de aprendizaje, construir indicadores académicos, perfilar estudiantes, encontrar riesgos, orientar intervenciones pedagógicas y fortalecer procesos de mejora continua y no únicamente en educación básica, capacitación empresarial o analítica comercial, salvo si se hace referencia a contrastes conceptuales por alguna razón. Su alcance incluye fundamentos de personalización del aprendizaje, conceptualización de Learning Analytics, fuentes de datos, indicadores, modelos descriptivos, predictivos y prescriptivos, sistemas de recomendación, tutorización académica apoyada en datos, diseño instruccional fundamentado en analíticas, inteligencia artificial, evaluación de impacto, ética de datos, justicia algorítmica, gobernanza institucional y retos de implementación.

Sección 1

Educación Superior virtual y personalización del aprendizaje

Transformación digital de la Educación Superior

La transformación digital de la Educación Superior no se reduce a la incorporación de plataformas o sistemas administrativos, en el contexto universitario, digitalizar procesos y transformar la institución no son acciones equivalentes. La digitalización puede limitarse a trasladar materiales, trámites o comunicaciones a entornos tecnológicos; la transformación digital, en cambio, exige revisar modelos pedagógicos, formas de gestión académica, cultura institucional, capacidades docentes, servicios de apoyo y mecanismos de toma de decisiones.

Esta distinción es determinante para entender por qué adquiere importancia Learning Analytics en la educación virtual, puesto que los datos solo tienen valor educativo cuando están dentro de una estrategia institucional orientada a la mejora del aprendizaje y la de la calidad académica.

Una distinción importante para comprender el alcance del cambio en la Educación Superior consiste en diferenciar la digitalización de la transformación digital, que se orienta principalmente a convertir procesos y recursos en formatos tecnológicos, mientras que la transformación digital implica una reconfiguración más profunda de la institución, sus prácticas pedagógicas, su cultura organizacional y sus mecanismos de decisión. La Tabla 1 resume estas diferencias.

Tabla 1. Diferencias entre digitalización y transformación digital.

Criterio	Digitalización	Transformación digital
Definición	Proceso de conversión de materiales, trámites, comunicaciones o servicios analógicos en formatos digitales.	Es un proceso integral de cambio institucional que replantea la enseñanza, la gestión, la cultura organizativa y la toma de decisiones mediante el uso estratégico de tecnologías y datos.
Alcance	Operativo e instrumental.	Estratégico, organizacional y pedagógico.
Propósito principal	Mejorar eficiencia, rapidez y acceso a procesos o recursos.	Rediseñar la institución para dar respuesta a necesidades formativas, mejorar la calidad del aprendizaje, reforzar la permanencia, favorecer la innovación.
Enfoque de cambio	Sustitución o automatización de procedimientos existentes.	Reconfiguración de modelos académicos, administrativos y culturales.
Relación con la docencia	Permite trasladar materiales o actividades a plataformas digitales.	Exige rediseñar experiencias de aprendizaje, evaluación, acompañamiento y retroalimentación en función del entorno digital.

Criterio	Digitalización	Transformación digital
Relación con los datos	Genera registros y trazas de uso, muchas veces con fines administrativos o de control.	Utiliza los datos como evidencia para comprender trayectorias, tomar decisiones, anticipar riesgos y personalizar apoyos educativos.
Rol institucional	Puede implementarse de forma aislada en áreas específicas.	Requiere articulación entre autoridades, docentes, unidades técnicas, sistemas de información y políticas institucionales.
Impacto esperado	Modernización de procesos, reducción de tiempos y mayor disponibilidad de recursos.	Mejora integral de la experiencia educativa, fortalecimiento de capacidades institucionales, cultura digital y toma de decisiones basada en evidencia.
Riesgos	Confundir uso de tecnología con innovación educativa; limitarse a “subir” contenidos a un aula virtual.	Implementar cambios sin gobernanza, sin preparación docente, sin criterios éticos o sin una estrategia clara de uso pedagógico de los datos.

La digitalización es un camino necesario, pero no suficiente para promover procesos de cambio significativo para la universidad, la transformación digital debe ser una manera o una forma más amplia de la que la tecnología se conecte con la innovación pedagógica, la gestión institucional, el desarrollo de las capacitaciones del profesorado y el uso estratégico de los datos. Esta precisión conceptual reviste especial importancia el campo de Learning Analytics, donde el valor de los datos no radica en ellos, sino en su lectura pedagógica y en su potencial para guiar acciones de mejora y personalización del aprendizaje.

Las instituciones de Educación Superior enfrentan una presión creciente para responder a escenarios híbridos, virtuales y flexibles, esa presión no proviene únicamente de la disponibilidad de tecnologías, sino de cambios en las trayectorias estudiantiles, en las expectativas de acceso, en la diversificación de perfiles y en la necesidad de sostener experiencias formativas más personalizadas. La literatura sobre transformación digital universitaria ha señalado que las instituciones deben repensarse como sistemas complejos, multiproceso y multiactorales, donde la tecnología incide en la docencia, la investigación, la gestión y la relación con la sociedad [1].

Esta comprensión amplia de la transformación digital exige identificar las dimensiones que intervienen en el cambio universitario. Como se muestra en la Figura 1, la transformación digital en Educación Superior integra componentes pedagógicos, organizacionales, tecnológicos, docentes y éticos que deben articularse en torno a una estrategia institucional centrada en la mejora del aprendizaje.



Figura 1. Dimensiones de la transformación digital en Educación Superior.

En los entornos virtuales, esta reorganización se vuelve visible en la manera en que la universidad diseña cursos, acompaña estudiantes, evalúa aprendizajes y usa evidencia para tomar decisiones, las plataformas de gestión del aprendizaje, los sistemas de información académica, las bibliotecas digitales, las herramientas de videoconferencia y los recursos colaborativos producen registros que pueden ayudar a comprender patrones de participación, avance, desempeño e interacción. Esos datos, sin embargo, no se pueden interpretar como espejos transparentes, o muestreos del aprendizaje. Un estudiante tiene baja actividad en plataforma porque su conectividad es mala, tiene mucha carga laboral, le resulta difícil organizar su trabajo o utiliza materiales que ha descargado, una alta frecuencia de acceso no garantiza una adecuada comprensión.

Learning Analytics se ubica precisamente en esa tensión entre disponibilidad de datos e interpretación pedagógica, su aporte no consiste en acumular métricas, sino en apoyar procesos de observación, análisis, interpretación, intervención y evaluación. Una institución digitalmente madura no es la que posee más herramientas, sino la que define qué problemas académicos desea abordar, qué indicadores son pertinentes, quién puede interpretarlos, qué acciones se derivan de ellos y cómo se evalúa su impacto.

La transformación digital también modifica el trabajo docente, en la educación virtual, enseñar no equivale a trasladar una clase presencial a una plataforma, sino a diseñar experiencias de aprendizaje con secuencias, actividades, recursos, evaluación y retroalimentación adecuados al entorno digital. Los docentes necesitan leer evidencias distribuidas en distintos sistemas: entregas tardías, ausencias en foros, resultados parciales, navegación irregular, participación colaborativa o patrones de desconexión. Estas evidencias pueden mejorar la capacidad de acompañamiento, pero solo si se interpretan con criterio profesional y no como señales automáticas de desinterés, bajo rendimiento o riesgo.

Desde la perspectiva de la personalización del aprendizaje, la digitalización abre posibilidades de atender trayectorias diversas a la vez que se sigue manteniendo el marco común de calidad académica. La personalización no quiere decir que se desintegre el currículo, ni que le deleguemos la toma de decisiones pedagógicas a algoritmos, sino que se utilice información relevante y pertinente para ofrecer apoyos, recursos, retroalimentaciones y tutorías más adecuadas. La educación virtual puede facilitar esa personalización cuando el diseño institucional se hace con la integración de tecnologías, datos y mediación docente.



Figura 2. Modelo de personalización basada en analíticas.

En síntesis, la transformación digital de la Educación Superior constituye el marco institucional que permite comprender la importancia de Learning Analytics. Los entornos virtuales generan datos, pero la mejora del aprendizaje depende de la capacidad universitaria para convertir esos datos en conocimiento pedagógico y en acciones de acompañamiento. La personalización del aprendizaje requiere, por tanto, una transformación digital centrada en el estudiante, sostenida por criterios académicos y regulada por principios éticos.

Entornos virtuales de aprendizaje en contextos universitarios

Los entornos virtuales de aprendizaje constituyen espacios digitales organizados para desarrollar procesos de enseñanza, aprendizaje, comunicación, evaluación y seguimiento académico, estos entornos no deben entenderse como simples repositorios de documentos ni como extensiones técnicas de la clase presencial. Su sentido pedagógico depende de cómo integran objetivos formativos, actividades, recursos, interacción, evaluación y retroalimentación. Si se produce una débil integración o una escasa resistencia con este sentido pedagógico, la plataforma funciona como un simple contenedor de tareas; si, en cambio, la integración es fuerte acabará por ser un espacio bien estructurado para poder articular trayectorias de aprendizaje y permitir obtener evidencias que nos sirvan para el acompañamiento.

La literatura sobre aprendizaje virtual en Educación Superior muestra que la virtualización educativa se relaciona con el uso de tecnologías, la autonomía del estudiante, el rol docente, la sostenibilidad de las experiencias formativas y la necesidad de diseñar actividades que no dependan exclusivamente de la transmisión de contenidos [2]. Lo que nos lleva a reconocer que un entorno virtual tiene una dimensión tecnológica, una dimensión pedagógica y comunicacional, aunque el reverso de la moneda también es cierto: la herramienta no es suficiente ni para asegurarse que haya colaboración, interacción u aprendizaje; éstas requieren de un objetivo de enseñanza y aprendizaje, del acompañamiento del profesorado y de las condiciones institucionales.



Figura 3. EVA como ecosistema pedagógico.

La Figura 3 permite comprender el Entorno Virtual de Aprendizaje como un ecosistema pedagógico integrado, en el que los objetivos de aprendizaje orientan la selección de recursos, el diseño de actividades, los procesos de comunicación, la interacción entre los participantes y las estrategias de evaluación. La retroalimentación, el seguimiento, las trazas de interacción y la analítica de aprendizaje permiten generar evidencias útiles para acompañar la trayectoria académica del estudiante. El EVA no solo se limita a guardar contenidos, sino que, además, articula componentes pedagógicos, comunicativos, tecnológicos para ayudar a dar orden al propio aprendizaje, tomar decisiones y mejorar de forma continua la experiencia de formación.

Los entornos virtuales suelen articular varias funciones, desde distribuir materiales, organizar actividades, gestionar entregas, evaluar desempeños, alojar foros, facilitar comunicación, registrar calificaciones y conservar trazas de interacción. A partir de estas funciones se generan datos educativos que pueden alimentar procesos de Learning Analytics. La calidad de esos datos depende de la calidad del diseño pedagógico, si una actividad no tiene un propósito claro, el indicador asociado a su entrega o participación tendrá valor limitado; si un foro se usa solo como requisito formal, el número de intervenciones no revelará necesariamente aprendizaje colaborativo.

La aceptación y uso de los entornos virtuales por parte de los estudiantes también resultan relevantes. Estudios sobre modelos de aceptación tecnológica en educación superior han mostrado que la utilidad percibida, las condiciones de uso y la metodología didáctica influyen en la intención de uso y en el aprendizaje percibido [3]. Esta relación es importante en Learning Analytics para que los datos de plataforma tengan sentido desde una experiencia subjetiva y académica. Poca participación puede estar relacionada con la interfaz, con la claridad de las instrucciones, con la relevancia de las tareas, con la carga académica o con la percepción de utilidad del entorno.

La mediación pedagógica es otro componente central, en los entornos virtuales, la presencia docente no se expresa solo mediante sesiones sincrónicas, sino en la claridad de la ruta, la pertinencia de los recursos, la calidad de la retroalimentación, la regulación de la interacción y la capacidad de orientar al estudiante cuando aparecen dificultades. Esta mediación debe leerse junto con la autonomía estudiantil, el rol docente y la metodología didáctica, porque el entorno virtual solo adquiere sentido formativo cuando articula condiciones tecnológicas con decisiones pedagógicas verificables [2][3].

La interacción es una condición decisiva para la calidad de los entornos virtuales. Puede darse entre estudiante y contenido, entre estudiantes, entre estudiante y docente, y entre estudiante e institución. Cada tipo de interacción produce señales distintas. La consulta de recursos puede informar sobre acceso al contenido; la participación en foros puede mostrar intercambio académico; los mensajes al docente pueden revelar necesidades de apoyo; las entregas sucesivas pueden mostrar progreso o rezago. Learning Analytics puede integrar estas señales, pero su interpretación requiere comprender la función pedagógica de cada actividad.

Los entornos virtuales también permiten experiencias colaborativas, aunque estas no surgen de manera automática. La colaboración en línea exige herramientas adecuadas, organización de roles, tareas interdependientes, criterios de evaluación y acompañamiento. Investigaciones recientes sobre herramientas colaborativas en entornos virtuales de educación superior online muestran la diversidad de recursos utilizados y la necesidad de ajustarlos a la complejidad del aula virtual y al perfil de los participantes [4]. Para la personalización del aprendizaje, esta dimensión es relevante, dado que no todos los estudiantes atienden a la misma manera de participar ni necesitan los mismos apoyos para lograr integrarse en las dinámicas colaborativas.

Los entornos virtuales presentan límites que Learning Analytics puede ayudar a identificar, pero no resolver por sí solo. Entre ellos se encuentran la desconexión estudiantil, la sobrecarga de actividades, la retroalimentación tardía, la baja interacción, la fragmentación de herramientas y las dificultades de accesibilidad. Los datos pueden señalar patrones problemáticos, pero la mejora requiere decisiones pedagógicas: rediseñar actividades, simplificar rutas, ajustar cargas, diversificar recursos, fortalecer tutorías o intervenir tempranamente.

En síntesis, los entornos virtuales de aprendizaje son el escenario donde se producen buena parte de los datos educativos que sostienen Learning Analytics. Su valor para la personalización depende de que la plataforma sea entendida como un ambiente pedagógico, no como una infraestructura neutra. La analítica del aprendizaje puede enriquecer el seguimiento académico cuando se apoya en diseños virtuales coherentes, indicadores válidos y mediación docente capaz de convertir información en acompañamiento.

Personalización del aprendizaje: fundamentos pedagógicos

La personalización del aprendizaje parte del reconocimiento de que los estudiantes no aprenden de manera homogénea, sus trayectorias, ritmos, conocimientos previos, condiciones tecnológicas, motivaciones, responsabilidades externas y formas de participación configuran experiencias diferenciadas. Estas diferencias pueden hacerse más visibles mediante registros de plataforma, resultados de evaluación y patrones de interacción; también pueden quedar ocultas si la institución reduce el seguimiento a calificaciones finales o a métricas superficiales. Personalizar el aprendizaje exige, por tanto, una comprensión pedagógica amplia, no solo una capacidad técnica de adaptar contenidos.

Es correcto establecer la diferencia entre la personalización y otros conceptos allegados a la misma. La individualización se relaciona generalmente con la modificación del ritmo, o de la secuencia, para un alumno determinado. La diferenciación implica una variación de las estrategias, de las actividades, o de los apoyos, a partir de grupos de alumnos con necesidades similares.

La adaptación conlleva modificar dinámicamente recursos o actividades en función del rendimiento o de las respuestas del alumno. La personalización integra estas posibilidades, pero va más allá: busca configurar una experiencia educativa pertinente según necesidades, trayectoria, desempeño, intereses y contexto, sin perder los objetivos académicos comunes.

Tabla 2. Diferencias entre individualización, diferenciación, adaptación y personalización.

Concepto	Definición	Foco ajuste	del Rol del estudiante y del docente	Ejemplo en educación superior virtual
Individualización	Ajuste del ritmo, la secuencia o el nivel de apoyo para un estudiante, manteniendo los mismos objetivos generales de aprendizaje.	Ritmo y progresión individual.	El estudiante avanza según su propio progreso; el docente acompaña, orienta y regula el seguimiento.	Permitir que un estudiante complete módulos de un curso virtual a distinta velocidad, con actividades de refuerzo según su avance.
Diferenciación	Variación de estrategias, recursos o actividades para atender necesidades de grupos de estudiantes con características o dificultades similares.	Estrategias y apoyos para grupos.	El docente diseña alternativas según perfiles o necesidades; el estudiante participa en propuestas acordadas con su grupo en situación académica.	Ofrecer recursos introductorios para un grupo con dificultades de comprensión y actividades de ampliación para otro grupo con mayor dominio previo.

Concepto	Definición	Foco ajuste	del Rol del estudiante y del docente	Ejemplo en educación superior virtual
Adaptación	Modificación dinámica de recursos, actividades o secuencias en función del desempeño, las respuestas o las interacciones registradas durante el aprendizaje.	Respuesta al desempeño a la evidencia de aprendizaje.	El estudiante interactúa con recursos ajustables; el docente interpreta los datos y decide o valida los cambios pedagógicos.	Un sistema recomienda ejercicios adicionales o modifica la secuencia de contenidos cuando detecta errores recurrentes en una evaluación en línea.
Personalización	Configuración integral de una experiencia de aprendizaje pertinente según necesidades, trayectoria, desempeño, intereses y contexto del estudiante, sin perder los objetivos académicos comunes.	Trayectoria formativa integral y pertinencia educativa.	El estudiante asume mayor agencia y autorregulación; el docente orienta, acompaña y articula apoyos, decisiones pedagógicas y uso de datos.	Diseñar rutas flexibles con recursos, tutorías y retroalimentación diferenciada para acompañar la trayectoria de cada estudiante en un programa virtual.

Fuente: Elaboración propia a partir de de-Benito, Moreno-García y Villatoro Moral [5].

La Tabla 2 permite precisar las diferencias entre individualización, diferenciación, adaptación y personalización, conceptos que suelen utilizarse de manera cercana, pero que no son equivalentes. Mientras la individualización se enfoca principalmente en el ritmo o la progresión de cada estudiante, la diferenciación organiza apoyos para grupos con necesidades similares y la adaptación modifica recursos o actividades según evidencias de desempeño.

La personalización por su parte, vincula estas posibilidades en un itinerario formativo más amplio, de un modo que se consideran las necesidades, el contexto, los intereses, el nivel de ejecución y la agencia sin perder para nada los objetivos académicos compartidos.

La personalización no debe confundirse con la satisfacción inmediata de preferencias individuales, el aprendizaje superior implica exigencia intelectual, apropiación de marcos conceptuales, desarrollo de competencias, participación en comunidades académicas y construcción de autonomía. Personalizar no significa eliminar la dificultad ni reducir la formación a rutas cómodas; significa ofrecer apoyos pertinentes para que el estudiante pueda enfrentar esa dificultad con mejores condiciones. Por esa razón, la personalización se vincula con equidad, permanencia y calidad.

Las tecnologías digitales han ampliado las posibilidades de personalizar itinerarios, recursos y actividades. Investigaciones sobre codiseño de itinerarios personalizados en enseñanza superior han señalado que las tendencias metodológicas basadas en flexibilización y participación activa requieren configuraciones tecnológicas capaces de facilitar decisiones compartidas entre estudiantes y docentes [5]. Este planteamiento ubica la personalización en un plano pedagógico y participativo, no únicamente algorítmico. El estudiante no es un receptor pasivo de recomendaciones; debe participar progresivamente en la regulación de su trayectoria.

Learning Analytics aporta a la personalización porque permite identificar señales que pueden orientar apoyos diferenciados. Un estudiante que entrega actividades con retraso, consulta pocos recursos, obtiene bajos resultados en evaluaciones diagnósticas o reduce su participación puede requerir acompañamiento específico. No obstante, esas señales deben interpretarse con cautela. Los datos muestran comportamientos registrados, no explicaciones completas. La personalización basada en analíticas debe combinar indicadores con juicio docente, comunicación directa y conocimiento del contexto.

La personalización también requiere evidencias de aprendizaje. Las prácticas mediadas por tecnologías digitales deben analizar no solo la actividad visible, sino la relación entre participación, resultados y procesos formativos. La discusión sobre evidencias de aprendizaje en prácticas digitales subraya la necesidad de comprender los procesos y resultados del aprendizaje en línea más allá de la simple presencia tecnológica [6].



Figura 4. Personalización basada en evidencias de aprendizaje.

La Figura 4 sintetiza la lógica pedagógica de una personalización del aprendizaje basada en evidencias, mostrando que los datos registrados en el entorno virtual solo adquieren valor formativo cuando son analizados en contexto e interpretados mediante juicio docente.

En función de la interpretación anterior, se pueden optar dar soporte en retroalimentación oportuna y generar evidencias de nueva creación que hagan posible la revisión de los avances y puedan hacer variar las intervenciones, que la personalización no sólo está en función de tener datos sino de cómo los datos se entrelazan con decisiones pedagógicas de acompañamiento, de mejora del aprendizaje y de intervención a las necesidades de cada uno de los estudiantes.

Desde una perspectiva ética, la personalización puede convertirse en un mecanismo de apoyo o en una forma de etiquetamiento. Si un sistema clasifica a un estudiante como rezagado, de bajo rendimiento o en riesgo sin mediación humana, puede condicionar negativamente la respuesta institucional. La personalización responsable debe evitar perfiles cerrados y promover intervenciones revisables. Un indicador de riesgo debe abrir una conversación, no cerrar una posibilidad. La supervisión docente y tutorial es indispensable para que los datos no sustituyan la comprensión de la trayectoria estudiantil.

En Educación Superior virtual, la personalización también se relaciona con la autonomía. Un estudiante autónomo no es quien aprende sin apoyo, sino quien puede tomar decisiones informadas sobre su proceso, reconocer sus dificultades, organizar su tiempo y utilizar recursos de manera estratégica. Los dashboards estudiantiles, la retroalimentación formativa y las recomendaciones de recursos pueden fortalecer esta autonomía si se diseñan con claridad y propósito pedagógico. En cambio, pueden generar dependencia o confusión si entregan información excesiva, opaca o descontextualizada.

En síntesis, la personalización del aprendizaje constituye el fundamento pedagógico que da sentido a Learning Analytics en esta obra. Los datos educativos pueden ayudar a reconocer diferencias, anticipar necesidades y orientar apoyos, pero la personalización solo tiene valor si se vincula con equidad, autonomía, calidad académica y supervisión humana. La tecnología puede ampliar las posibilidades de adaptación; la decisión educativa sigue dependiendo de criterios pedagógicos.

Personalización en la Educación Superior virtual

La personalización en la Educación Superior virtual se concreta en decisiones pedagógicas que afectan contenidos, actividades, recursos, evaluación, retroalimentación, tutorías y trayectorias formativas. Su aplicación exige pasar de una visión general de la diversidad estudiantil a mecanismos específicos de acompañamiento. En un curso virtual, personalizar puede significar ofrecer recursos de refuerzo a quienes muestran dificultades, proponer actividades de ampliación a

estudiantes con avance sostenido, ajustar la retroalimentación según errores recurrentes, recomendar tutorías en momentos críticos o rediseñar una secuencia cuando los datos muestran bloqueos colectivos.

La personalización de contenidos no consiste en entregar materiales distintos de manera arbitraria. Debe responder a objetivos de aprendizaje, evidencias de desempeño y necesidades identificadas. Un estudiante que falla en una evaluación por desconocer conceptos previos requiere recursos distintos a quien falla por problemas de aplicación, lectura de instrucciones o falta de tiempo. Learning Analytics puede ayudar a distinguir patrones, pero la interpretación pedagógica define qué tipo de apoyo es pertinente. Los contenidos personalizados deben integrarse a rutas formativas coherentes y no convertirse en fragmentos aislados.

La personalización de actividades implica diseñar tareas con grados de dificultad, formatos o apoyos diferenciados. En entornos virtuales, esta diferenciación puede apoyarse en secuencias adaptativas, bancos de ejercicios, actividades colaborativas, simulaciones, casos o rutas alternativas. Las investigaciones sobre itinerarios personalizados en enseñanza superior destacan la importancia del codiseño, la agencia estudiantil y las configuraciones tecnológicas que permiten construir trayectorias flexibles [5]. Esta perspectiva evita reducir la personalización a una asignación automática de recursos y subraya la participación del estudiante en la construcción de su propio recorrido.

En la educación virtual, la retroalimentación tardía puede aumentar la desconexión, mientras que la retroalimentación oportuna puede orientar ajustes antes de que el estudiante acumule rezago. Learning Analytics puede identificar errores frecuentes, tiempos de entrega, intentos fallidos, patrones de revisión y resultados parciales. Estos datos permiten personalizar mensajes, sugerir recursos, priorizar tutorías o modificar instrucciones. La retroalimentación automatizada debe manejarse con cuidado: puede ser útil para aspectos procedimentales, pero no reemplaza la valoración docente cuando se trata de razonamiento, argumentación, creatividad o desempeño complejo.




Figura 5. Ciclo de retroalimentación personalizada.

La Figura 5 representa la retroalimentación personalizada como un proceso cíclico que inicia con la participación del estudiante en una actividad, continúa con una evaluación parcial y permite detectar patrones de dificultad, retraso o baja participación. A partir de esta evidencia, el docente puede emitir mensajes de orientación, proponer tutorías, recomendar recursos de refuerzo o ajustar la ruta de aprendizaje. El seguimiento posterior permite verificar si la intervención produjo avances y, en caso necesario, reorganizar los apoyos. De esta manera, la retroalimentación deja de ser únicamente una comunicación sobre el desempeño y se convierte en una acción pedagógica orientada a sostener la trayectoria formativa del estudiante en entornos virtuales.

Los entornos virtuales también permiten personalizar recursos educativos. Un mismo objetivo puede abordarse mediante lecturas, videos, infografías, ejercicios interactivos, foros, casos o simulaciones. La elección de recursos debe considerar accesibilidad, carga cognitiva, conectividad, necesidades de refuerzo y nivel de autonomía. Estudios sobre aceptación de entornos virtuales señalan que la utilidad percibida y la metodología didáctica influyen en el aprendizaje percibido por los estudiantes [3]. Esto sugiere que personalizar recursos no solo implica variar formatos, sino asegurar que esos recursos sean comprensibles, pertinentes y funcionales para la tarea académica.

La tutoría virtual apoyada en datos es otra vía de personalización. Los tutores pueden priorizar estudiantes con señales de desconexión, bajo rendimiento, entregas tardías o baja interacción. También pueden identificar grupos con dificultades comunes y organizar intervenciones colectivas. La clave está en que la alerta analítica no sea el final del proceso, sino el inicio de una acción pedagógica. Un sistema puede sugerir que un estudiante requiere apoyo, pero la tutoría debe indagar causas, negociar estrategias y ofrecer acompañamiento proporcional.

Los sistemas de recomendación académica son una aplicación mejorada de esta tecnología, pueden recomendar recursos, actividades, itinerarios, pares de trabajo o tutorías. Se debe evitar que su uso en Educación Superior respalde decisiones no transparentes, el estudiante y el profesorado deben saber la razón por la cual se recomienda un recurso o la finalidad pedagógica de tal o cual recurso. Las recomendaciones también deben ser revisables, dado que un perfil conductual puede cambiar ante nuevas evidencias, nuevas informaciones o mejoras en la trayectoria de un estudiante.

La personalización en educación virtual tiene límites. Puede generar sobrecarga si se ofrecen demasiadas rutas, desigualdad si algunos estudiantes reciben apoyos de menor calidad, o dependencia si el sistema decide por el estudiante. También puede reproducir sesgos si los datos históricos reflejan desigualdades previas. Por ello, la personalización basada en Learning Analytics debe orientarse a ampliar oportunidades, no a segmentar rígidamente a los estudiantes. La supervisión humana, la transparencia y la evaluación de impacto son condiciones indispensables.

Resumiendo, la personalización de la Educación Superior virtual se produce cuando las evidencias permiten personalizar los apoyos pedagógicos a diferencia de los anteriores. Learning Analytics aporta la señal; la institución convertirá eso en acciones, la personalización responsable no automatiza la educación, sino que hace posible la capacidad docente e institucional para acompañar los caminos distintos.

Brechas, permanencia y éxito académico en la educación virtual

La educación virtual amplía oportunidades de acceso, pero también revela y puede profundizar brechas que afectan la permanencia y el éxito académico. Las desigualdades no se limitan a la disponibilidad de conexión o dispositivos. Incluyen competencias digitales, condiciones de estudio, tiempo disponible, capital académico familiar, habilidades de autorregulación, comprensión lectora, autonomía, motivación, salud emocional y posibilidad de recibir apoyo institucional.

En Educación Superior, estas brechas inciden de manera directa en la participación estudiantil, el desempeño, la continuidad y la finalización de los programas.

El abandono en modalidades virtuales y a distancia ha sido identificado como un problema relevante para las instituciones universitarias. García Aretio sostiene que el abandono y el fracaso en estudios a distancia constituyen una preocupación extendida y que requieren respuestas pedagógicas basadas en diálogo didáctico mediado, orientación y apoyo institucional[7]. Esta perspectiva desvía la interpretación del abandono de una cuestión exclusivamente individual hacia una interpretación relacional, el estudiante permanece con más probabilidades cuando se producen interacciones personales, acompañamiento y situaciones académicas viables.




Figura 6. Indicadores de riesgo de abandono y permanencia en educación virtual
Nota. Con base en García Aretio [7].

El gráfico permite visualizar indicadores tempranos que pueden asociarse con riesgo de abandono en la educación virtual, tales como baja conexión, entregas tardías, poca interacción, bajo rendimiento parcial, ausencia en tutorías y limitada respuesta al acompañamiento. Estos indicadores no deben interpretarse de manera aislada ni punitiva, sino como señales para activar mecanismos de orientación, tutoría, retroalimentación y apoyo institucional.

Las brechas digitales son una primera dimensión. Un estudiante puede estar matriculado en un programa virtual y, al mismo tiempo, acceder a la plataforma desde dispositivos compartidos, conexiones inestables o espacios domésticos poco adecuados para estudiar. Estas condiciones afectan la regularidad de conexión, la

participación sincrónica, la entrega de actividades y la posibilidad de interactuar con recursos multimedia. Learning Analytics puede mostrar desconexiones o baja actividad, pero no explica por sí mismo sus causas. Los indicadores deben complementarse con mecanismos de comunicación, encuestas, tutorías y lectura contextual.

Las brechas cognitivas y académicas también inciden en la permanencia. Algunos estudiantes llegan a la Educación Superior con dificultades en lectura académica, escritura, razonamiento matemático, gestión del tiempo o estrategias de estudio. En entornos virtuales, estas dificultades pueden amplificarse porque el estudiante debe organizar su proceso con mayor autonomía. La revisión sistemática sobre aprendizaje virtual en Educación Superior destaca la importancia de la autonomía del estudiante, el rol docente y la sostenibilidad de las experiencias virtuales [2]. Desde Learning Analytics, esto implica observar no solo resultados finales, sino trayectorias de avance, patrones de interacción y momentos donde se acumulan obstáculos.

Las brechas socioeducativas se relacionan con condiciones laborales, familiares, económicas y culturales. Muchos estudiantes universitarios virtuales combinan estudio con empleo, cuidado de familiares u otras responsabilidades. La flexibilidad de la modalidad puede favorecer su acceso, pero también puede producir aislamiento si la institución no diseña mecanismos de acompañamiento. La permanencia en Educación Superior a distancia ha sido abordada como un desafío que exige estrategias y acciones institucionales orientadas a sostener al estudiante durante su trayectoria [8]. Esta mirada resulta coherente con una personalización del aprendizaje centrada en apoyos oportunos y no en clasificación punitiva.

Learning Analytics puede contribuir a la permanencia mediante sistemas de alerta temprana, estos sistemas identifican señales como ausencia prolongada, baja participación, retrasos, bajo desempeño, disminución de actividad o falta de interacción. Una alerta no equivale a una intervención. Para que sea útil, debe existir un protocolo claro: quién revisa la señal, cómo se contacta al estudiante, qué tipo de apoyo se ofrece, cómo se registra la respuesta y cómo se evalúa el resultado, sin esta cadena de acción, la analítica se convierte en monitoreo pasivo.

El éxito académico en educación virtual no debe definirse únicamente como aprobación o finalización. También incluye aprendizaje significativo, autorregulación, participación, satisfacción, desarrollo de competencias y sentido de pertenencia. Las prácticas educativas mediadas por tecnologías digitales requieren evidencias que permitan comprender procesos y resultados de aprendizaje [6]. Por todo esto,

Learning Analytics no puede limitarse a la calificación e incluso a la combinación de la calificación con ciertos indicadores de rendimiento del tipo participativo (préstamos, sesiones, tiempo, etc.), sino que tendrá que integrar los indicadores propios de la participación y del rendimiento en tareas auténticas.

La detección de estudiantes en riesgo exige cautela ética. Clasificar a un estudiante como “en riesgo” puede ayudar a priorizar apoyos, pero también puede producir estigmatización si se usa sin criterio. Los modelos analíticos pueden generar falsos positivos o falsos negativos, y los datos disponibles pueden reflejar desigualdades previas. La institución debe evitar que las alertas se conviertan en etiquetas fijas. Un estudiante en riesgo no es un problema estadístico, sino una persona cuya trayectoria puede cambiar si recibe apoyo pertinente.

A modo de conclusión, el hecho de que las trayectorias sean permanentes justifica el uso de Learning Analytics en la Educación Superior virtual, siempre y cuando su diseño sea pedagógico y ético. Los datos pueden ayudar a detectar señales tempranas, pero la mejora en los elementos de la enseñanza y del aprendizaje dependerá de la capacidad de las instituciones para intervenir de forma oportuna y pertinente. La personalización del aprendizaje cobra sentido cuando contribuye a sostener trayectorias formativas, a reducir las desigualdades y a ampliar las posibilidades realmente efectivas de dar lugar al aprendizaje esperado.

Sección 2

Fundamentos de Learning Analytics en contextos universitarios

Conceptualización de Learning Analytics

Learning Analytics puede entenderse como un campo de investigación y práctica orientado a recopilar, organizar, analizar e interpretar datos sobre los estudiantes, sus interacciones y sus contextos de aprendizaje, con el propósito de comprender y mejorar los procesos educativos. Esta definición exige una precisión inicial: la analítica del aprendizaje no se agota en la medición ni en la visualización de datos. Su sentido educativo aparece cuando la información producida permite tomar decisiones pedagógicas, diseñar apoyos, ajustar actividades, mejorar la retroalimentación y orientar intervenciones institucionales. En Educación Superior virtual, donde buena parte de la actividad académica deja registros digitales, Learning Analytics ofrece un marco para convertir esas trazas en evidencias interpretables.



Figura 7. Elementos constitutivos de Learning Analytics.

La literatura iberoamericana ha insistido en que las analíticas de aprendizaje deben vincularse con la toma de decisiones pedagógicas, no solo con la gestión técnica de datos. En estudios sobre Educación Superior, se ha definido la analítica del aprendizaje como un proceso que articula recopilación, medición, análisis e informe de datos de desempeño y contexto, útiles para promover aprendizajes de calidad [9]. Esta formulación resulta adecuada para la obra porque coloca la calidad del aprendizaje en el centro y evita que la discusión se reduzca a plataformas, algoritmos o tableros de control.

La relación entre datos, análisis, interpretación y acción educativa constituye el núcleo del concepto. Los datos son registros disponibles: accesos, entregas, calificaciones, mensajes, participación en foros, navegación, tiempo de conexión, interacción con recursos o resultados de evaluaciones.

El análisis permite organizar esos registros, detectar patrones, describir comportamientos o estimar riesgos, implica comprender lo que esos patrones son en el contexto de un diseño pedagógico determinado, un plan de acción educativo que finalmente hace la práctica educativa porque ya ha traducido ese conocimiento en retroalimentación, tutoría, rediseño de actividades, recomendaciones de recursos o ajustes institucionales. Sin esto, Learning Analytics dejaría de estar completo.

El campo se ha desarrollado dentro de una educación cada vez más mediada por datos, la expansión de los sistemas digitales de aprendizaje ha hecho que la información generada por estudiantes, docentes y recursos se convierta en una parte habitual de la vida académica [10]. Dicha disponibilidad supone abrir la puerta a muchas posibilidades, pero también induce a preguntarse qué es lo que se está observando, para qué lo está observando, quién es el que está interpretando la información y qué consecuencias se están derivando para los estudiantes. La analítica del aprendizaje no debe ser presentada como una técnica neutral, es una práctica situada, fruto de decisiones pedagógicas, institucionales y éticas.

Learning Analytics opera como un ciclo de mejora continua cuando conecta observación, análisis, intervención y evaluación. Un curso virtual puede mostrar baja participación en una actividad; la analítica permite identificar el patrón, pero la mejora depende de revisar si las instrucciones fueron claras, si la carga fue adecuada, si el recurso era accesible o si el momento del curso produjo acumulación de tareas. La intervención puede consistir en enviar retroalimentación, ajustar la actividad, ofrecer una tutoría o rediseñar una secuencia. Luego se requiere evaluar si la acción produjo cambios en participación, desempeño o satisfacción.

Conviene diferenciar medición, monitoreo, predicción y personalización. Medir implica registrar o cuantificar un fenómeno educativo. Monitorear supone observar su evolución en el tiempo. Predecir busca estimar resultados probables, como riesgo de abandono o bajo desempeño, a partir de datos disponibles. Personalizar, en cambio, exige usar la información para ofrecer apoyos, rutas, recursos o intervenciones más pertinentes.

En el plano académico, puede apoyar el seguimiento de cursos, programas y trayectorias estudiantiles, en el plano pedagógico, puede orientar retroalimentación,

tutorías, diseño instruccional y evaluación formativa. En el plano institucional, puede contribuir a políticas de permanencia, aseguramiento de calidad, innovación educativa y toma de decisiones basada en evidencia.

Esta amplitud explica su valor, pero también sus riesgos: cuanto más amplio es el alcance, mayor debe ser la claridad sobre responsabilidades, límites de uso, protección de datos y supervisión humana.

En síntesis, Learning Analytics no debe entenderse como una tecnología aislada, sino como una práctica académica e institucional que usa datos para comprender y mejorar el aprendizaje. Su valor no reside en la acumulación de indicadores, sino en la capacidad de producir interpretaciones pedagógicamente válidas y acciones oportunas. Para la personalización del aprendizaje en entornos virtuales de Educación Superior, esta conceptualización permite mantener un principio rector: los datos deben estar al servicio del estudiante y de la calidad formativa, no al servicio de una vigilancia sin finalidad educativa.

Evolución histórica y tendencias internacionales

Learning Analytics surge en un contexto de expansión de la educación digital, crecimiento de los entornos virtuales, consolidación de los sistemas de gestión del aprendizaje y aumento de la capacidad institucional para almacenar y procesar datos. Aunque las instituciones educativas siempre han usado información académica, la novedad del campo radica en la escala, continuidad y granularidad de los registros generados por plataformas digitales. Las huellas dejadas por la actividad de los alumnos se hacen visibles con matices y detalles muy diferentes, como pueden ser los accesos, series de navegación, interacción con materiales, participación en foros, tiempos de entrega, intentos de evaluación y fundamentos de la comunicación.



Figura 8. Evolución de Learning Analytics en la Educación Superior.

El desarrollo internacional del campo se relaciona con la convergencia de varias tradiciones: investigación educativa, ciencias del aprendizaje, minería de datos, inteligencia artificial, estadística aplicada, visualización de información y educación mediada por tecnologías. La literatura especializada ha descrito la analítica del aprendizaje y la educación basada en datos como un campo en expansión, impulsado por la presencia creciente de sistemas digitales en espacios formales, abiertos y a lo largo de la vida [10]. Dicha expansión no sólo resulta del tener disponible una técnica, también expresa la necesidad de entender trayectorias educativas más diversas y de intervenir con más oportunidad.

Durante sus primeros años, Learning Analytics estuvo fuertemente asociado con la identificación de estudiantes en riesgo, el seguimiento de participación y la predicción de desempeño. Estos usos siguen siendo relevantes, pero el campo ha ampliado su alcance hacia el diseño pedagógico, la retroalimentación, la autorregulación, la evaluación de intervenciones, la equidad y la gobernanza de datos.

La relación entre Learning Analytics y los LMS ha sido decisiva, plataformas como Moodle, Canvas, Blackboard u otros sistemas institucionales concentran gran parte de la interacción académica en cursos virtuales e híbridos. Estos entornos permiten registrar participación, progreso, calificaciones, acceso a recursos y comunicación, lo que facilita el desarrollo de indicadores y modelos analíticos. No obstante, la evolución del campo ha mostrado que los datos del LMS son útiles pero insuficientes: deben interpretarse junto con diseño pedagógico, contexto estudiantil, evaluación, tutoría y condiciones institucionales.

El auge alcanzado por el Big data educativo ha reforzado la expectativa de que las universidades pueden decidir mejor si analizan grandes volúmenes de información, esa expectativa debe matizarse, los datos educativos no hablan por sí mismos; requieren marcos interpretativos, criterios pedagógicos y protocolos de acción. La investigación sobre algoritmos educativos basados en datos advierte que la expansión de soluciones automatizadas exige marcos pedagógicos capaces de orientar su uso y evitar que la toma de decisiones quede subordinada a procesos opacos [10].

Otra tendencia internacional es la incorporación de Learning Analytics a procesos de aseguramiento de calidad. Las universidades buscan evidencias sobre participación, rendimiento, satisfacción, permanencia y efectividad de diseños formativos. Al mismo tiempo, la calidad no puede limitarse a medidas de actividad, un curso puede

tener un gran nivel de conexión, pero también puede propiciar un aprendizaje superficial; también puede tener una baja o nula participación en una herramienta concreta, porque los estudiantes hagan uso de otros medios para el estudio. La analítica contribuye al aseguramiento de calidad cuando se integra con evaluación académica, revisión curricular y acompañamiento docente.

La inteligencia artificial educativa ha introducido nuevas posibilidades y nuevas tensiones, modelos predictivos, sistemas de recomendación, tutores inteligentes, asistentes conversacionales y herramientas de retroalimentación automatizada amplían el campo de acción de Learning Analytics. En síntesis, la evolución de Learning Analytics muestra el paso de una preocupación inicial por medir y predecir hacia una comprensión más amplia de la educación basada en datos. El campo se ha internacionalizado porque responde a problemas comunes de las universidades: permanencia, rendimiento, calidad, personalización y toma de decisiones. Su desarrollo futuro dependerá menos de la sofisticación técnica aislada y más de la capacidad de articular datos, pedagogía, ética e institución.

Learning Analytics, Educational Data Mining y Academic Analytics

Learning Analytics, Educational Data Mining y Academic Analytics forman parte de un ecosistema más amplio de análisis de datos educativos, pero no deben usarse como conceptos intercambiables. Comparten fuentes de información, técnicas computacionales y preocupaciones por la mejora educativa; sin embargo, difieren en su foco, sus preguntas principales, sus actores prioritarios y sus formas de intervención. Distinguirlos es necesario para evitar confusiones metodológicas y para diseñar estrategias institucionales coherentes.

Educational Data Mining se orienta al descubrimiento de patrones en datos educativos mediante técnicas de minería de datos, aprendizaje automático, clasificación, agrupamiento, reglas de asociación, modelos predictivos u otros procedimientos computacionales. Su interés principal se concentra en desarrollar o aplicar métodos capaces de identificar regularidades, estimar comportamientos, reconocer perfiles o predecir resultados. En Educación Superior, puede utilizarse para explorar relaciones entre variables académicas, detectar patrones de rendimiento, identificar grupos de estudiantes o estimar riesgo de abandono.

Learning Analytics comparte técnicas con Educational Data Mining, pero su centro no es únicamente el método analítico. Su propósito se vincula con comprender y optimizar el aprendizaje, así como los entornos donde este ocurre. Una aplicación colombiana en Educación Superior diferencia Learning Analytics como un enfoque

principalmente asociado a procesos descriptivos y de apoyo a la toma de decisiones, mientras que Educational Data Mining aparece más vinculado a procesos predictivos y de descubrimiento de conocimiento [11]. Aunque esta distinción no agota toda la discusión internacional, ayuda a comprender cómo ambos campos pueden complementarse.

Academic Analytics, por su parte, se ubica más cerca de la gestión institucional. Su interés se orienta hacia la toma de decisiones estratégicas sobre programas, retención, eficiencia académica, desempeño institucional, asignación de recursos o políticas universitarias. Mientras Learning Analytics mira con mayor atención los procesos de aprendizaje y enseñanza, Academic Analytics suele trabajar en una escala más agregada: cohortes, carreras, facultades, indicadores institucionales o sistemas de gestión. Esta diferencia de escala tiene consecuencias éticas y operativas, porque las decisiones pueden afectar tanto a estudiantes individuales como a grupos completos.

Tabla 3. Diferencias entre Learning Analytics, Educational Data Mining y, Academic Analytics.

Criterio	Learning Analytics	Educational Data Mining	Academic Analytics
Definición	Enfoque orientado a recopilar, analizar e interpretar datos sobre los estudiantes y sus contextos de aprendizaje para comprender y mejorar el proceso educativo.	Campo centrado en aplicar técnicas computacionales y de minería de datos para descubrir patrones en grandes conjuntos de datos educativos.	Uso de datos institucionales y académicos para apoyar la gestión universitaria, la planificación estratégica y la toma de decisiones administrativas.
Unidad de análisis	Estudiante, curso, actividad, interacción y trayectoria de aprendizaje.	Variables, registros, patrones, secuencias de comportamiento y modelos predictivos.	Programa, carrera, facultad, cohorte, institución y sistema académico.
Objetivo principal	Mejorar el aprendizaje, personalizar apoyos, detectar riesgos académicos y orientar intervenciones pedagógicas.	Descubrir patrones ocultos, construir modelos predictivos, clasificar comportamientos y explicar relaciones entre variables educativas.	Mejorar la gestión institucional, evaluar el desempeño académico global y apoyar decisiones sobre permanencia, eficiencia terminal, matrícula y calidad.
Actores que lo usan	Docentes, tutores, estudiantes, coordinadores académicos y unidades de apoyo pedagógico.	Investigadores, analistas de datos, científicos de datos, equipos técnicos y especialistas en IA educativa.	Autoridades universitarias, directores de carrera, decanos, unidades de planificación, departamentos de calidad y gestión académica.
Tipo de datos de datos usados	Datos de calificaciones, participación en foros, respuestas a pruebas, retención, deserción,	LMS/EVA, Bases de datos educativas, logs de navegación, clics, aprobación, reprobación,	Datos de matrícula, aprobación, reprobación, retención, deserción,

Criterio	Learning Analytics	Educational Data Mining	Academic Analytics
	accesos a recursos, evaluaciones, retroalimentación y tutorías.	secuencias de interacción, datos históricos y variables demográficas.	titulación, carga docente, rendimiento por carrera y reportes institucionales.
Ejemplo universitario	Un docente revisa un dashboard del aula virtual para identificar estudiantes con baja participación y enviar retroalimentación oportuna.	Un equipo de investigación aplica algoritmos de clasificación para predecir tasas de deserción por qué estudiantes tienen mayor probabilidad de diseñar políticas de reprobar una asignatura virtual.	Una universidad analiza tasas de deserción por carrera y cohorte para diseñar políticas de permanencia estudiantil.

Los tres enfoques son complementarios cuando se integran con claridad. Educational Data Mining puede aportar modelos y técnicas para explorar datos; Learning Analytics puede traducir evidencias en acciones pedagógicas; Academic Analytics puede conectar esos hallazgos con decisiones institucionales. El problema aparece cuando una universidad adopta modelos predictivos sin mediación educativa, dashboards sin protocolo de intervención o indicadores institucionales que no dialogan con la experiencia real de estudiantes y docentes. La complementariedad exige gobernanza, criterios de validez y responsabilidades definidas.

La confusión conceptual también puede producir errores prácticos. Si se presenta Learning Analytics solo como predicción, se reduce su potencial pedagógico. Si se entiende Academic Analytics como simple control administrativo, se pierde su capacidad para orientar políticas de apoyo. Si Educational Data Mining se aplica sin interpretación educativa, los patrones descubiertos pueden convertirse en conclusiones débiles o incluso injustas. La analítica educativa requiere reconocer que una correlación no equivale a una explicación y que un modelo con buen desempeño estadístico no necesariamente produce una intervención pedagógica adecuada.

Esta distinción contribuye a ordenar responsabilidades, por ejemplo, los equipos técnicos necesitarán tomar decisiones sobre la infraestructura, la integración de datos, el desarrollo de modelos; los docentes y tutores tendrán que entender las señales presentes en el diseño del curso; las autoridades podrán utilizar la información agregada para mejorar los programas y/o políticas; los comités de ética tendrán que proceder a la revisión de las finalidades, de los riesgos y/o de las condiciones de uso. Ninguno de estos actores puede apoderarse sólo del proceso.

En síntesis, Learning Analytics, Educational Data Mining y Academic Analytics pertenecen a una misma familia de prácticas basadas en datos, pero cumplen funciones distintas. Para la personalización del aprendizaje, Learning Analytics ocupa

un lugar articulador porque conecta técnicas de análisis con decisiones pedagógicas y acompañamiento estudiantil. Su valor aumenta cuando se nutre de métodos robustos de minería de datos y cuando dialoga con políticas institucionales, pero disminuye cuando se confunde con predicción automática o con gestión administrativa desvinculada del aprendizaje.

Ciclo de vida de Learning Analytics

El ciclo de vida de Learning Analytics describe el recorrido mediante el cual los datos educativos se transforman en acciones de mejora. Este ciclo no debe entenderse como una secuencia puramente técnica, sino como un proceso socio-pedagógico en el que intervienen decisiones sobre qué datos se recogen, cómo se procesan, quién los interpreta, qué acciones se autorizan y cómo se evalúan sus efectos. En Educación Superior virtual, esta perspectiva es especialmente importante porque la abundancia de registros digitales puede crear la ilusión de que analizar datos equivale automáticamente a mejorar el aprendizaje.

Una propuesta de implementación ampliamente útil organiza el proceso en cinco etapas: entornos de aprendizaje, recolección de datos en bruto, manipulación de datos e ingeniería de características, análisis y modelos, y aplicación educativa [12]. Esta secuencia facilita comprender que Learning Analytics no comienza en el algoritmo, sino que se inicia en donde se produce la experiencia formativa. Si un curso está mal diseñado, si las actividades no responden a objetivos claros o si la forma de utilizar la plataforma de aprendizaje es superficial, los datos generados serán de escaso valor pedagógico.

La captura de datos constituye la primera operación visible del ciclo, puede incluir registros de acceso al LMS, navegación, entregas, calificaciones, participación en foros, interacción con recursos, respuestas en cuestionarios, mensajes, asistencia a sesiones sincrónicas o información administrativa. La decisión sobre qué capturar debe responder a una finalidad educativa explícita, no todo dato disponible es necesario, ni todo dato útil es legítimo en cualquier contexto. La recolección indiscriminada incrementa riesgos de privacidad y puede producir indicadores difíciles de interpretar.

Limpiar e integrar datos son etapas poco visibles, pero decisivas, ocurre que los registros educativos suelen estar incompletos, duplicados, desordenados o distribuidos en sistemas diferentes. Antes de analizarlos, es necesario depurarlos, unificar formatos, resolver inconsistencias, definir unidades de análisis y construir variables significativas. En esta fase aparece la ingeniería de características:

transformar datos brutos en indicadores interpretables, como regularidad de conexión, avance acumulado, retraso en entregas, participación sostenida o cambios en el desempeño. La calidad de estos indicadores condiciona la validez de cualquier decisión posterior.

El procesamiento y análisis pueden adoptar distintos niveles:

- El análisis descriptivo muestra qué ocurrió: participación, rendimiento, accesos o progreso.
- El análisis diagnóstico busca comprender posibles causas o relaciones.
- El análisis predictivo estima resultados probables, como riesgo académico o abandono.
- El análisis prescriptivo propone acciones recomendadas, recursos o intervenciones.

Estos niveles no se deben presentarse como una escalera ineludible de sofisticación, ya que una buena descripción puede ser más útil que una predicción débil. La mejor elección vendrá condicionada por el problema educativo, la calidad, la disponibilidad de datos, la capacidad de actuación de la institución.

La visualización desarrolla un rol de intermediario, entre el análisis y la interpretación, dashboards, reportes, gráficos, mapas de progreso que sintetizan información para estudiantes, docentes, tutores o autoridades. Su diseño debe responder a preguntas pedagógicas concretas. Un tablero que muestra demasiados indicadores puede confundir; uno que reduce el aprendizaje a semáforos puede simplificar en exceso; uno que no explica sus criterios puede generar desconfianza. La visualización valiosa permite comprender, priorizar y actuar, no solo observar datos.

La intervención educativa es el punto donde el ciclo se vuelve significativo. Una alerta, una predicción o una visualización no mejoran por sí mismas el aprendizaje. Se requiere definir qué hacer con la información: contactar al estudiante, ofrecer tutoría, ajustar una actividad, recomendar un recurso, modificar una evaluación, abrir un espacio de orientación o revisar el diseño del curso. Experiencias de analíticas en acción muestran que las intervenciones basadas en evidencia requieren capacitación, reuniones de apoyo, acuerdos de acción y seguimiento de resultados [13]. La analítica, por tanto, necesita una cadena institucional de respuesta.

El ciclo concluye, y vuelve a comenzar, con la evaluación de impacto. Toda intervención debería revisarse para saber si produjo cambios en participación, rendimiento, permanencia, satisfacción, autorregulación o calidad del aprendizaje.

Evaluar impacto también implica reconocer límites: una mejora puede depender de múltiples factores y no únicamente de la intervención analítica. Por ello, Learning Analytics ha de funcionar como mejora continua, con revisión de datos, ajustes de modelos, aprendizaje institucional y participación de los actores implicados.

En síntesis, el ciclo de vida de Learning Analytics integra captura, limpieza, análisis, visualización, interpretación, intervención y evaluación. Su fortaleza no está en cada etapa aislada, sino en la coherencia entre ellas. Con el objetivo de personalizar el aprendizaje en, este ciclo debe diseñarse con una finalidad pedagógica explícita, datos relevantes, interpretación contextual y acciones verificables institucionales.

Actores involucrados en Learning Analytics

Learning Analytics involucra a múltiples actores porque sus efectos atraviesan la experiencia de aprendizaje, la docencia, la tutoría, el diseño curricular, la gestión institucional, la infraestructura tecnológica y la protección de datos. Ningún actor puede asumir el proceso completo de manera aislada. Una implementación responsable requiere distribuir responsabilidades, establecer protocolos de comunicación y reconocer que la interpretación de los datos educativos no es una tarea exclusivamente técnica.

Tabla 4. Actores involucrados en Learning Analytics.

Actor	Información Necesaria	Responsabilidad principal	Decisiones que puede tomar	que Riesgos que debe evitar
Estudiante	Progreso académico, calificaciones, actividades pendientes, retroalimentación, nivel de participación, recursos recomendados, alertas de desempeño.	Usar la información analítica para autorregular aprendizaje, identificar dificultades y participar activamente en su proceso formativo.	Revisar recursos para apoyo, su tutoría, su tiempo de estudio, mejorar y participación ajustar estrategias de aprendizaje.	Interpretar los datos como etiquetas definitivas, depender excesivamente del sistema, ignorar la retroalimentación docente o comparar su desempeño de forma descontextualizada.
Docente	Participación estudiantil, entregas, resultados de evaluaciones, interacción en foros, acceso a recursos, patrones de error y alertas tempranas.	Interpretar datos desde perspectiva pedagógica, diseñar intervenciones oportunas, mejorar aprendizaje.	Ajustar actividades, reforzar contenidos, modificar recursos y personalizar retroalimentación, activar alertas para derivar el tutoría.	Reducir el aprendizaje a métricas, asumir que baja actividad significa desinterés, usar datos sin contexto o delegar decisiones pedagógicas únicamente al sistema.
Tutor académico	Alertas de riesgo, historial de estudiante	Acompañar de estudiante	al Contactar en estudiante,	al Estigmatizar al estudiante, actuar solo

Actor	Información Necesaria	Responsabilidad principal	Decisiones que puede tomar	que Riesgos que evitar	que debe
	participación, desempeño acumulado, trayectoria académica, dificultades reportadas seguimiento de intervenciones previas.	riesgo académico mediante orientación, seguimiento articulación docentes y unidades de apoyo.	programar tutorías, cuando el riesgo es alto, recomendar estrategias de información sensible y estudio, derivar a sin autorización o con apoyo académico o aplicar intervenciones o psicosocial y genéricas. monitorear avances.		
Coordinador de carrera	Indicadores de asignatura, tasas de aprobación, reprobación, abandono, permanencia, rendimiento por cohorte y efectividad de intervenciones.	por Supervisar el desempeño académico programa coordinar acciones de mejora basadas en evidencia.	el Reorganizar apoyos académicos, solicitar ajustes y metodológicos, coordinar tutorías, interpretar datos sin priorizar asignaturas críticas y proponer mejoras curriculares.	Tomar decisiones punitivas contra docentes o estudiantes, interpretar datos sin contexto, usar indicadores incompletos o ignorar brechas estructurales.	
Equipo tecnológico	Fuentes de datos, calidad de registros, interoperabilidad de sistemas, seguridad, permisos de acceso, arquitectura tecnológica y funcionamiento de dashboards.	Garantizar disponibilidad, integridad, seguridad e interoperabilidad de los datos y plataformas de Learning Analytics.	la Integrar sistemas, configurar dashboards, e gestionar permisos, autorizados, asegurar bases de datos, automatizar técnicamente reportes y corregir errores técnicos.	Exponer datos sensibles, accesos no autorizados, generar indicadores pedagógicamente débiles o descuidar la trazabilidad.	
Autoridad académica	Indicadores institucionales, tendencias de permanencia, desempeño por facultad o carrera, impacto de intervenciones, riesgos académicos y reportes estratégicos.	Orientar políticas académicas, asignar recursos y promover una cultura institucional basada en evidencia.	Definir políticas de permanencia, financiar sistemas de apoyo, fortalecer capacitación docente, aprobar protocolos y priorizar intervenciones institucionales.	Usar la analítica como mecanismo de control, imponer decisiones sin participación docente, invisibilizar desigualdades o priorizar eficiencia sobre calidad educativa.	

Los estudiantes son el eje del proceso, sus interacciones, sus resultados, sus trayectorias generan una buena parte de los datos que son analizados, pero no han de ser considerados como solamente fuentes de información. Tienen derecho a comprender qué datos se recogen, con qué finalidad, quién los usa y qué consecuencias pueden derivarse. También pueden beneficiarse de dashboards, retroalimentación, alertas, recomendaciones y recursos personalizados, siempre que

estos instrumentos favorezcan la autorregulación y no produzcan vigilancia opaca o etiquetamiento.

Los docentes ocupan un lugar decisivo porque conocen el diseño de las actividades, los objetivos de aprendizaje, las exigencias disciplinares y las dificultades frecuentes del curso. Su papel no consiste únicamente en recibir reportes, sino en interpretar señales, contrastarlas con la experiencia pedagógica y decidir intervenciones. Estudios sobre herramientas de Learning Analytics en entornos virtuales muestran que las acciones docentes pueden vincularse con monitoreo, evaluación, retroalimentación e intervención dentro de ambientes como Moodle [14]. Esto confirma que la analítica necesita mediación profesional para convertirse en apoyo educativo.

Los tutores académicos cumplen una función de acompañamiento más focalizada. Pueden revisar alertas tempranas, contactar estudiantes, identificar barreras, orientar estrategias de estudio y derivar casos a servicios institucionales. Su intervención es especialmente importante cuando los datos muestran desconexión, rezago o bajo desempeño. La tutorización en base de analíticas debe evitar las respuestas automáticas, puesto que del mismo nivel de riesgo se pueden extraer causas académicas, laborales, tecnológicas, emocionales o familiares. El contacto humano permite discernir patrones semejantes de necesidades diferentes.

En torno a la estructura, secuencia, carga, recursos, evaluación, experiencia de usuario, los diseñadores instruccionales y equipos de innovación educativa ofrecen una óptica. Pueden llegar a utilizar evidencias para rediseñar cursos, mejorar las instrucciones, ajustar actividades, diversificar recursos o reorganizar rutas de aprendizaje. En la educación virtual, muchas dificultades no dependen solo del estudiante, sino de diseños poco claros o de cargas mal distribuidas. Learning Analytics permite identificar estos problemas cuando se analiza la actividad colectiva y no únicamente el rendimiento individual.

Los coordinadores de programa y autoridades universitarias usan información agregada para mejorar políticas académicas, permanencia, calidad, asignación de recursos y apoyo estudiantil. Su responsabilidad es asegurar que las analíticas no queden como iniciativas aisladas de un curso o una plataforma, sino que formen parte de una estrategia institucional. La implementación de Learning Analytics requiere colaboración entre actores, definición de políticas, capacidades tecnológicas y alineación con objetivos educativos [12].

Los equipos de tecnología educativa y analítica de datos sustentan la infraestructura del proceso, integran fuentes, aseguran calidad de datos, configuran sistemas de información, desarrollan modelos, documentan indicadores y mantienen sistemas. Su trabajo debe dialogar con docentes y autoridades, porque un modelo técnicamente correcto puede ser pedagógicamente débil si no responde a una pregunta educativa pertinente. La infraestructura debe estar al servicio de la interpretación y la intervención, no al revés.

Los responsables de protección de datos, comités de ética y áreas jurídicas son indispensables, Learning Analytics trabaja con información sensible sobre desempeño, conducta, participación y trayectoria académica. Por ello, se necesitan criterios de minimización, transparencia, consentimiento cuando corresponda, seguridad, control de acceso y revisión de riesgos.

La literatura sobre algoritmos educativos basados en datos advierte que la expansión de sistemas automatizados exige responsabilidad, transparencia y marcos pedagógicos de interpretación [10].

Una vez sintetizado esto; Learning Analytics se presenta como una práctica donde se encuentran todos los estudiantes, docentes, tutores, diseñadores, autoridades, equipos técnicos y responsables éticos, su aplicación será buena en la medida en que cada actor conozca su papel y la institución sea capaz de construir circuitos de comunicación entre todos ellos. La personalización del aprendizaje solo puede sostenerse cuando la evidencia analítica se convierte en acción coordinada, comprensible y pedagógicamente justificada.

Arquitecturas tecnológicas para Learning Analytics

Las arquitecturas tecnológicas para Learning Analytics son el conjunto de sistemas, bases de datos, integraciones, procesos, modelos y visualizaciones que permiten convertir registros educativos en información útil para la acción académica. Estas arquitecturas suelen articular LMS, sistemas de gestión académica, herramientas de evaluación, plataformas de videoconferencia, repositorios de recursos, sistemas de tutoría y bases institucionales. Su diseño no debe responder solo a criterios de disponibilidad técnica, sino a necesidades pedagógicas, éticas y organizacionales.

El LMS ocupa un lugar central porque concentra gran parte de la actividad educativa en cursos virtuales e híbridos, desde allí pueden obtenerse registros de acceso, avance, participación, entregas, interacción con recursos y resultados de evaluaciones. No obstante, una arquitectura de Learning Analytics no puede

depender exclusivamente del LMS, los sistemas administrativos aportan datos sobre matrícula, permanencia, trayectoria, historial académico o carga del estudiante; las bibliotecas digitales ofrecen señales de consulta; las tutorías registran acompañamiento; las encuestas recogen percepción y experiencia. La integración de estas fuentes permite obtener una mejor comprensión sobre el recorrido de la jefatura, pero a su vez va a suponer un crecimiento en la complejidad técnica y ética.



Figura 9. Arquitectura institucional para Learning Analytics.

Pueden estar dirigidos a estudiantes, docentes, tutores, coordinadores o autoridades, y cada destinatario requiere información distinta, un estudiante necesita comprender su progreso, sus pendientes y posibles acciones de mejora. Un docente necesita identificar patrones del curso, dificultades frecuentes y estudiantes que requieren apoyo. Para un tutor es necesario priorizar casos y registrar las intervenciones, una autoridad necesita información agregada para tomar decisiones de programa, si un mismo tablero intenta servir de uno y de otro modo, es muy probable que no sirva bien para nadie.

Pueden identificar señales de riesgo académico, desconexión, retraso o bajo desempeño, su valor depende de la calidad de los datos, la claridad de los criterios y la existencia de un protocolo de respuesta. Una arquitectura puede producir alertas

técnicamente precisas y fracasar institucionalmente si nadie sabe quién debe actuar, qué apoyo ofrecer o cómo registrar el resultado. Por ello, la tecnología debe incluir flujos de trabajo, roles y mecanismos de seguimiento.

Las herramientas de visualización y los sistemas de recomendación amplían las posibilidades de personalización, las primeras permiten explorar patrones, comparar trayectorias y hacer visibles relaciones entre participación, progreso y desempeño. Los segundos pueden sugerir recursos, actividades, tutorías o rutas de aprendizaje. Ambos componentes requieren cautela, una visualización puede inducir interpretaciones simplistas si no muestra contexto; una recomendación puede reforzar trayectorias desiguales si se basa en datos sesgados.

La interoperabilidad es una condición técnica clave. Las universidades suelen operar con sistemas fragmentados, formatos distintos y bases que no dialogan entre sí. Sin interoperabilidad, la analítica depende de procesos manuales, datos incompletos o integraciones frágiles. Modelos recientes de arquitectura para instituciones de Educación Superior han explorado el uso de nubes híbridas, infraestructura escalable y análisis de datos para apoyar servicios académicos basados en Learning Analytics [15]. Pese a que cada institución de enseñanza superior ha de adaptar su solución a su propio contexto, la necesidad común es construir una infraestructura que permita integrar datos sin sacrificar seguridad ni gobernanza.

La integración con inteligencia artificial introduce nuevas capas arquitectónicas como, modelos de clasificación, predicción, recomendación o procesamiento de lenguaje pueden ampliar las capacidades analíticas. No obstante, estos modelos requieren datos de calidad, documentación, evaluación de desempeño, control de sesgos y revisión periódica.

La inteligencia artificial no debe incorporarse como adorno tecnológico ni como sustituto del juicio académico, su uso es pertinente cuando responde a un problema educativo definido y cuando sus resultados pueden ser interpretados y discutidos por los actores responsables.

Toda arquitectura de Learning Analytics tiene límites dado que puede fallar por datos incompletos, indicadores mal definidos, problemas de seguridad, baja adopción docente, falta de capacitación, sobrecarga de información o ausencia de protocolos de intervención. También puede producir efectos no deseados si transforma la experiencia educativa en un sistema de control permanente. Por ello, el diseño tecnológico debe acompañarse de gobernanza, formación, evaluación de impacto y participación de los usuarios.

Resumiendo, una arquitectura tecnológica para Learning Analytics no es solo un soporte de datos; es el sistema de mediación entre los registros digitales y las decisiones educativas. Su calidad depende de la integración entre plataformas, modelos, visualizaciones, protocolos y actores, para personalizar el aprendizaje en Educación Superior virtual, la arquitectura debe ser técnicamente robusta, pedagógicamente pertinente, éticamente responsable y suficientemente flexible para adaptarse a distintos cursos, programas y trayectorias estudiantiles.

Sección 3

Datos educativos, indicadores académicos y perfilado del estudiante

Naturaleza de los datos educativos

Los datos educativos son registros producidos durante la vida académica de los estudiantes y durante la operación institucional de los procesos formativos, en entornos virtuales, estos datos pueden originarse en plataformas de aprendizaje, sistemas de gestión académica, evaluaciones en línea, foros, videoconferencias, bibliotecas digitales, tutorías, encuestas y servicios de apoyo. El valor que esta comunicación puede llegar a tener no se basa exclusivamente en su tamaño, sino en la oportunidad de aplicar su potencial para la comprensión de procesos de aprendizaje, participación, desempeño, permanencia y acompañamiento. Para Learning Analytics, la relevancia de los datos como base es lo que les da valor; es el punto de inicio y no el de llegada.

Una primera distinción útil separa datos estructurados, semiestructurados y no estructurados:

- Los datos estructurados se organizan en campos definidos, como calificaciones, fechas de entrega, número de accesos, matrícula, créditos aprobados o historial académico.
- Los documentos semiestructurados tienen un cierto tipo de organización formal, pero no necesariamente siguen un formato rígido (por ejemplo, registros de navegación, metadatos de recursos web o secuencias de interacción).
- Los tipos no estructurados ya incluyen las producciones discursivas como los textos de los foros de discusión, los mensajes, los audios, los vídeos, los comentarios abiertos o las producciones de los estudiantes.

Cada tipo de dato exige métodos de procesamiento distintos y ofrece posibilidades de interpretación diferentes. Conviene diferenciar datos académicos, administrativos, conductuales y contextuales. Los datos académicos se relacionan con desempeño, evaluación, avance y logro. Los conductuales provienen de la actividad registrada en plataformas: accesos, clics, participación, permanencia, interacción con recursos o tiempos de entrega, los contextuales permiten comprender condiciones que influyen en el aprendizaje, como conectividad, carga

laboral, responsabilidades familiares, disponibilidad de tiempo o necesidades de apoyo.

El LMS es una importante fuente de datos dado que registra una buena parte de la actividad digital que tiene lugar en el curso, no obstante, los datos obtenidos no constituyen la representación completa del estudiante ni del aprendizaje; fácilmente, un acceso frecuente puede denotar compromiso a la hora de realizar la actividad, pero también puede constatar una situación de desorientación. Un tiempo prolongado en una página puede expresar estudio, interrupción o problemas de navegación. Una baja participación puede deberse a desconexión, uso de materiales descargados, carga laboral o dificultades con la plataforma. Por ello, los datos educativos requieren interpretación contextual y triangulación con otras fuentes.

Tabla 5. Tipos de datos educativos.

Tipo de dato	Descripción	Ejemplo en EVA	Fuente probable	Uso en Learning Analytics
Datos estructurados	Información organizada en campos definidos, generalmente numérica o categórica, fácil de almacenar y analizar.	Calificación en una tarea, fecha de entrega, estado de actividad o completada, y número de intentos en una evaluación.	de LMS/EVA, sistema académico, módulo de calificaciones, avance, de registros de evaluación.	Calcular indicadores de rendimiento, de cumplimiento, aprobación, riesgo académico y progreso del estudiante.
Datos semiestructurados	Información con cierta organización interna, pero no totalmente estandarizada; puede requerir procesamiento previo.	Registros de navegación, mensajes, historial de clics, participación en foros con fecha, usuario y categoría.	de Logs del LMS/EVA, sistemas de mensajería, plataformas de videoconferencia, repositorios digitales.	Identificar patrones de participación, frecuencia de acceso, secuencias de interacción y momentos de desconexión.
Datos no estructurados	Información libre, textual, audiovisual o documental no sigue formato fijo.	Respuestas abiertas, comentarios en foros, mensajes docente, grabaciones de intervenciones en actividades colaborativas.	Foros, abiertas, en videoconferencias, portafolios digitales, entregados a documentos o estudiantes.	Analizar calidad argumentativa, necesidades de apoyo, sentimientos, dudas frecuentes, comprensión conceptual o participación cualitativa.
Datos académicos	Información relacionada directamente con el desempeño, avance	Notas, actividades aprobadas, con evaluaciones fallidas, tareas y pendientes,	LMS/EVA, sistema académico, rúbricas, evaluaciones, tareas de calificaciones.	Monitorear rendimiento, detectar bajo desempeño, personalizar

	resultados formativos estudiante.	avance del unidad.	por	recursos, tutorías.	activar
Datos administrativos	Información institucional vinculada matrícula, carrera, cohorte, asignaturas, permanencia gestión académica.	Estado matrícula, carrera, con nivel, número créditos, historial de asignaturas, de modalidad de registros y estudio, retiros o repitencias.	de Sistema académico secretaría académica, sistema matrícula, trayectorias de registros o administrativos.	Analizar permanencia, abandono, eficiencia terminal, carrera, cohortes críticas y necesidades institucionales de apoyo.	
Datos conductuales /contextuales	Información sobre comportamiento, participación, condiciones de acceso y contexto de interacción del estudiante.	Frecuencia ingreso al tiempo de conexión, recursos consultados, participación en foros, horarios de acceso, uso de materiales descargados.	de LMS/EVA, EVA, web, de digital, de videoconferencia, encuestas de contexto, tutorías.	analítica Identificar compromiso, participación, desconexión, de hábitos de estudio, riesgo temprano y necesidades de acompañamiento personalizado.	

La calidad de los datos es una condición crítica, estudios recientes sobre analítica multimodal muestran que el ruido en los atributos puede afectar el desempeño de modelos automatizados de estimación de la calidad de la colaboración [16]. Aunque este trabajo se enfoca en colaboración, su advertencia es trasladable a la totalidad de Learning Analytics: información incompleta, contradicciones, registros incorrectos o poco representativos pueden dar lugar a interpretaciones deficientes. Si los indicadores están contruidos sobre registros defectuosos, la personalización podría entorpecer el arreglo de los errores en lugar de solucionarlos.

Los datos educativos tampoco son neutrales, reflejan decisiones de diseño, condiciones de acceso, reglas institucionales, prácticas docentes y características de las plataformas. Una actividad no registrada no desaparece del aprendizaje, pero queda fuera del análisis, un estudiante que estudia offline puede ser considerado inactivo. Una plataforma que registra clics lo registra a nivel de actividad, pero no a nivel de la comprensión puede incrementar la actividad. Learning Analytics debe reconocer estos límites para evitar conclusiones simplistas.

Los datos no estructurados abren posibilidades relevantes, pero también incrementan la complejidad. Textos de foros, respuestas abiertas o interacciones

comunicativas pueden ofrecer indicios de argumentación, colaboración, dudas o comprensión.

Su análisis requiere técnicas más sofisticadas y criterios éticos más cuidadosos, porque suelen contener expresiones personales, opiniones o información sensible. En estos casos, el principio de minimización resulta especialmente importante: no se debe analizar más información de la necesaria para el propósito educativo declarado.

Dicho de otra forma, la naturaleza de los datos educativos es heterogénea, pedagógicamente mediada y contextual. Para personalizar este aprendizaje, no solo es necesario recoger registros, sino también saber qué representan, qué ocultan, cómo fueron producidos, qué calidad ostentan y con base en qué decisiones se pueden sustentar. Learning Analytics comienza con datos, pero solo adquiere sentido cuando esos datos se convierten en evidencias válidas para acompañar trayectorias estudiantiles.

Fuentes de datos en entornos virtuales universitarios

Las fuentes de datos en entornos virtuales universitarios son diversas y responden a funciones académicas, administrativas, tecnológicas y de acompañamiento. Learning Analytics ha de reconocer esta diversidad, pues ninguna fuente de datos por sí sola es capaz de abarcar la trayectoria del estudiante, aunque el LMS puede registrar la participación y progreso en el curso, a la vez puede no proporcionar detalles de su trayectoria académica, sus condiciones de conexión (calidad, tipo de dispositivos), su carga de trabajo, las tutorías de las que haya podido beneficiarse, sus problemas personales, etcétera. La personalización del aprendizaje requiere integrar fuentes sin perder de vista su finalidad educativa y sus límites éticos.




Figura 10. Fuentes de datos para Learning Analytics.

El LMS suele ser la fuente más visible. Desde allí se obtienen accesos, navegación, entregas, calificaciones, intentos en cuestionarios, participación en foros, consulta de recursos y comunicación con docentes. Estos registros permiten construir indicadores de actividad, avance, regularidad y desempeño. Sin embargo, su interpretación depende del diseño del curso. Si una asignatura concentra el aprendizaje en actividades externas, el LMS puede subregistrar el esfuerzo real.

Los sistemas de gestión académica aportan datos de trayectoria: matrícula, programa, nivel, créditos aprobados, historial de aprobación, retiros, reprobaciones, carga académica y situación administrativa. Estos datos son útiles para comprender riesgo, permanencia y progresión.

En investigaciones sobre predicción del rendimiento académico se han usado variables académicas y antecedentes del estudiante para estimar desempeño, mostrando el valor de combinar información institucional con técnicas analíticas [17]. No obstante, estos datos deben usarse con cautela para evitar que antecedentes históricos se conviertan en etiquetas rígidas.

Las evaluaciones en línea son otra fuente importante, cuestionarios, tareas, rúbricas, exámenes, actividades prácticas y ejercicios interactivos nos ofrecen información sobre logro de objetivos, errores comunes, progreso, dificultades conceptuales, etc. A diferencia de los accesos o clics, las evaluaciones se vinculan más directamente con el aprendizaje esperado, aunque también tienen límites, una calificación puede

ocultar distintos tipos de error: falta de comprensión, mala lectura de instrucciones, ansiedad, problemas técnicos o ausencia de conocimientos previos. La analítica debe distinguir entre desempeño registrado y explicación pedagógica.

Los foros, mensajería y herramientas colaborativas permiten observar interacción académica. Pueden ofrecer señales sobre participación, construcción colectiva, dudas, liderazgo, aislamiento o colaboración. Su análisis, sin embargo, requiere criterios cualitativos y no solo conteo de mensajes. Dos intervenciones extensas pueden tener menor valor que una pregunta precisa; muchas respuestas pueden indicar colaboración o simple cumplimiento formal. La fuente comunicativa es valiosa cuando se interpreta según la función pedagógica asignada a la actividad.

Las sesiones sincrónicas añaden asistencia, participación o interacción; las bibliotecas digitales resultan en consulta de materiales; los repositorios muestran acceso a recursos de apoyo. Pero estas señales no necesariamente están ligadas al LMS o no aportan el mismo nivel de detalle, la fragmentación entre sistemas es uno de los principales obstáculos para una analítica institucional robusta. Modelos colaborativos de arquitectura de datos para Learning Analytics subrayan la necesidad de reestructurar datos institucionales para hacerlos útiles a investigadores, docentes y tomadores de decisión [18].

Las encuestas, diagnósticos y tutorías aportan información que difícilmente aparece en registros automáticos. Permiten conocer percepción de carga, satisfacción, motivación, condiciones de estudio, conectividad, necesidades de apoyo o experiencias de exclusión. Estos datos son esenciales para evitar interpretaciones reductivas. Un patrón de desconexión puede ser técnicamente similar en varios estudiantes, pero sus causas pueden ser distintas.

La integración de fuentes debe acompañarse de criterios de calidad, seguridad y gobernanza. Cuantas más fuentes se conectan, mayor es la capacidad de comprensión, pero también aumentan los riesgos de privacidad, sesgo, uso indebido y sobre interpretación. Una arquitectura de datos responsable define finalidades, permisos, niveles de acceso, mecanismos de anonimización cuando corresponda y protocolos de intervención. La riqueza de fuentes solo es valiosa si se traduce en mejores decisiones pedagógicas.

Para resumir, las fuentes de datos en el contexto virtual universitario abarcan plataformas, sistemas académicos, evaluaciones, comunicación, recursos, encuestas y tutorías. Su convergencia entrega una lectura más rica del aprendizaje y de los estudiantes, pero previene que se convierta en datos y, en este sentido, Learning

Analytics debe entremezclar las fuentes para apoyar la personalización, pero sin convertir al estudiante en un conjunto de registros tangibles.

Indicadores académicos para Learning Analytics

Los indicadores académicos son construcciones que sintetizan datos para observar, comparar o interpretar aspectos relevantes de la trayectoria estudiantil. En Learning Analytics no deben entenderse como verdades directas sobre el aprendizaje, sino como señales parciales que requieren contexto. Un indicador puede servir para identificar avance, dificultad, participación o riesgo, pero su valor dependerá de cómo se define, qué datos utiliza, qué parte del proceso representa y qué acción educativa deja entrever.

Tabla 6. Indicadores académicos para Learning Analytics.

Dimensión	Indicador	Utilidad para Learning Analytics
Acceso	Frecuencia de ingreso al aula virtual	Permite identificar si el estudiante mantiene contacto regular con el curso.
Participación	Intervenciones en foros, chats o actividades colaborativas	Ayuda a observar el nivel de interacción académica del estudiante.
Cumplimiento	Entrega de tareas y actividades	Permite detectar retrasos, incumplimientos o posibles señales de riesgo.
Desempeño	Calificaciones en tareas, pruebas y evaluaciones	Sirve para identificar dificultades de aprendizaje y necesidad de refuerzo.
Avance	Porcentaje de módulos o actividades completadas	Muestra el progreso del estudiante dentro del curso virtual.
Permanencia	Periodos de inactividad o abandono de actividades	Ayuda a anticipar riesgo de deserción o desvinculación académica.
Retroalimentación	Consultas, mensajes o solicitudes de apoyo	Permite reconocer necesidades de acompañamiento docente o tutoría.
Riesgo académico	Combinación de baja participación, bajo rendimiento e inactividad	Facilita la generación de alertas tempranas para intervenir oportunamente.

Entre los indicadores más comunes se encuentran los accesos a plataforma, la frecuencia de conexión y la regularidad de uso, estos datos pueden ofrecer señales iniciales sobre vinculación con el curso, pero tienen límites interpretativos importantes. Acceder muchas veces no equivale necesariamente a aprender; acceder poco no siempre significa desinterés. El estudiante puede descargar materiales, estudiar fuera de línea o usar canales alternativos. Por ello, los indicadores de acceso deben combinarse con información sobre actividades, desempeño, interacción y contexto.

El tiempo de permanencia suele utilizarse como indicador de dedicación, aunque es uno de los más delicados, un tiempo elevado puede reflejar estudio sostenido, pero también distracción, dificultad de navegación o una sesión abierta sin actividad real. Un tiempo bajo puede indicar revisión rápida o falta de compromiso, la analítica educativa debe evitar conclusiones automáticas a partir de este indicador. Su utilidad aumenta cuando se analiza junto con secuencias de navegación, entregas, resultados y participación.

La entrega de actividades y el progreso en el curso ofrecen señales más cercanas a la trayectoria académica. Fechas de entrega, retrasos, actividades no enviadas, avance en módulos y cumplimiento de hitos permiten identificar patrones de rezago. Estos indicadores son especialmente útiles para tutorías y alertas tempranas. Sin embargo, deben interpretarse según la carga académica, el calendario, la complejidad de las

tareas y las condiciones del estudiante, un retraso aislado no tiene el mismo significado que una acumulación progresiva de incumplimientos.

Los resultados de evaluaciones constituyen indicadores centrales, pero tampoco son autosuficientes. Calificaciones, intentos, errores frecuentes, desempeño por competencia o resultados en evaluaciones diagnósticas permiten orientar retroalimentación y recursos de apoyo. Estudios sobre predicción del rendimiento académico en Educación Superior han mostrado que los modelos pueden utilizar variables de desempeño y antecedentes para anticipar resultados, aunque su aplicación requiere comprender las condiciones institucionales y pedagógicas del caso [17]. La predicción no debe reemplazar la intervención, sino activar acompañamiento oportuno.

La participación en foros e interacción con recursos también se usa para observar compromiso académico. Número de publicaciones, respuestas, lecturas, visualizaciones o descargas pueden mostrar actividad, pero no siempre calidad. Un foro puede tener muchas intervenciones con bajo contenido académico, o pocas intervenciones con alto valor argumentativo. Por ello, los indicadores cuantitativos deben complementarse con criterios cualitativos, especialmente cuando se evalúa colaboración, pensamiento crítico o construcción colectiva.

Los indicadores de autorregulación son más complejos. Pueden inferirse a partir de regularidad de estudio, planificación de entregas, uso de retroalimentación, revisión de recursos, secuencias de actividad o respuesta a alertas. En educación virtual, estos indicadores son relevantes porque la autonomía del estudiante se vuelve decisiva. No obstante, deben construirse con cuidado para no confundir autorregulación con disponibilidad de tiempo o condiciones tecnológicas favorables. Un estudiante con alta responsabilidad laboral puede mostrar irregularidad sin carecer de compromiso.

Los indicadores de riesgo de abandono o probabilidad de aprobación combinan varias señales: bajo desempeño, retrasos, ausencia de actividad, disminución de participación, historial académico o falta de interacción. Pueden ayudar a priorizar apoyos, pero también pueden producir falsas alarmas o invisibilizar estudiantes que requieren ayuda y no aparecen en el modelo. La calidad del indicador depende de la calidad de los datos, la validez del modelo y la existencia de acciones institucionales posteriores.

En la práctica del presente modelo, los indicadores académicos son indicios orientadores, no son sustitutos del juicio pedagógico, Learning analytics necesita indicadores adecuados, contextualizados, relacionados con decisiones sobre las que

es posible actuar. En la personalización del aprendizaje, el indicador más interesante no es el más sofisticado, sino el que permite entender una necesidad y activar una indicación pertinente.

Indicadores de compromiso y participación estudiantil

El compromiso estudiantil en entornos virtuales se expresa mediante formas diversas de participación, dedicación, interacción, persistencia y autorregulación. Learning Analytics permite observar algunas de estas formas a partir de registros digitales, pero no puede capturar por completo la experiencia subjetiva del estudiante. La participación visible en plataforma es una parte del compromiso, no su totalidad. Por ello, los indicadores deben construirse con cautela y leerse junto con el diseño pedagógico, la carga académica y las condiciones de estudio.

La frecuencia de conexión permite observar si el estudiante mantiene contacto regular con el curso, si existen ausencias prolongadas o si aparece una disminución progresiva de actividad. Su valor aumenta cuando se analiza temporalmente, porque no basta con saber cuántas veces ingresó el estudiante, sino cuándo lo hizo, con qué regularidad y en relación con qué actividades.

Tabla 7. Indicadores de compromiso y participación estudiantil.

Dimensión	Indicador	Utilidad para Learning Analytics
Conexión	Frecuencia de ingreso al aula virtual	Permite observar si el estudiante mantiene contacto regular con el curso o si presenta ausencias prolongadas.
Regularidad	Distribución de la actividad durante la semana	Ayuda a identificar hábitos de estudio, organización del tiempo y posibles patrones de abandono.
Participación activa	Publicaciones en foros, chats o debates	Permite analizar el nivel de interacción visible del estudiante con sus compañeros y docentes.
Participación pasiva	Consulta de recursos, lecturas o revisión de materiales	Reconoce formas de participación menos visibles, pero importantes para el proceso de aprendizaje.
Interacción académica	Mensajes, respuestas, tutorías o trabajo colaborativo	Ayuda a observar la integración del estudiante en la dinámica académica y social del curso.
Persistencia	Continuidad en actividades y entregas	Permite detectar si el estudiante sostiene su participación a lo largo del curso.
Autorregulación	Uso de retroalimentación, revisión de pendientes y cumplimiento de metas	Sirve para identificar la capacidad del estudiante para organizar y ajustar su propio aprendizaje.
Desconexión	Disminución repentina de actividad o falta de respuesta	Permite activar alertas tempranas y acciones de acompañamiento oportuno.

Un estudiante que distribuye su actividad durante la semana puede mostrar un patrón de organización distinto a quien concentra todo su trabajo antes de la entrega.

Las analíticas del compromiso estudiantil han mostrado que los patrones temporales de participación pueden ofrecer información valiosa sobre la manera en que los estudiantes sostienen o abandonan su actividad a lo largo del curso [19]. Esta lectura temporal ayuda a identificar no solo cuánto participa el estudiante, sino cómo evoluciona su relación con el aprendizaje.

Deben ser contrastadas la participación activa y la participación pasiva, leer recursos, revisar instrucciones o consultar materiales puede ser una manera de participar indiscutible, aunque en menor proporción manifiesta que publicar en un foro o entregar una tarea. En cambio, intervenir ciertas veces no quiere decir que se acabe siendo profundo, los indicadores deben dar cuenta de diferentes formas de vinculación con el cursillo, la analítica del aprendizaje corre el riesgo de premiar lo que la plataforma puede recoger con facilidad y de invisibilizar actividades más silenciosas, como la lectura, la reflexión o la planificación.

La interacción con pares y docentes ofrece señales relevantes. Mensajes, respuestas, participación en foros, colaboración en documentos o asistencia a tutorías pueden mostrar integración académica y social. En entornos virtuales, estas interacciones ayudan a reducir aislamiento y favorecen la permanencia. Sin embargo, su análisis debe considerar la función asignada a cada actividad. Un curso basado en trabajo individual no producirá los mismos registros que uno diseñado con colaboración intensiva. Comparar indicadores sin considerar el diseño puede conducir a conclusiones injustas.

La investigación reciente sobre compromiso estudiantil y Learning Analytics muestra que el campo ha desarrollado múltiples formas de medir engagement, pero también advierte la necesidad de integrar dimensiones conductuales, cognitivas, afectivas y sociales [20]. Si lo que se indica es sólo lo que tiene que ver con lo conductual, la institución puede llegar a identificar actividad, pero no necesariamente podrá identificar motivación, comprensión, integración, pertenencia o percepción del apoyo. La baja actividad participativa puede ser la consecuencia de la desmotivación, pero también de la sobrecarga, la ansiedad o la falta de claridad.

Los patrones de desconexión son especialmente relevantes para la detección temprana. Una caída repentina de actividad, la ausencia en varias tareas consecutivas o la falta de respuesta a retroalimentación pueden indicar riesgo académico. Aun así,

la desconexión debe abrir una indagación, no cerrar un diagnóstico. El estudiante puede atravesar problemas técnicos, laborales, familiares o emocionales.

Los indicadores de compromiso también pueden usarse para fortalecer la autorregulación. Un dashboard estudiantil puede mostrar progreso, pendientes, comparación con metas personales o recomendaciones de estudio. Para que sea útil, debe evitar el exceso de información y presentar señales comprensibles. El objetivo no es vigilar al estudiante, sino ayudarlo a reconocer su trayectoria, anticipar dificultades y tomar decisiones informadas.

En conclusión, los indicadores de compromiso y participación son significativos ya que hacen posible entender la forma de relacionarse de un alumno determinado con un curso y activar apoyos en su momento. Su interpretación debe ir más allá de la actividad que se ve, a la vez que articula e integra dimensiones ideales y reales, así como dimensiones temporales, sociales, cognitivas o afectivas, haciendo que el Learning Analytics puede enriquecer el seguimiento del compromiso, pero evitando reducirlo a un patrón de clics.

Perfilado del estudiante en ambientes virtuales

El perfilado del estudiante en ambientes virtuales consiste en organizar información académica, conductual, contextual y de participación para comprender mejor su trayectoria y orientar apoyos. No se trata de construir una etiqueta fija, sino de elaborar una lectura dinámica y revisable. En Learning Analytics, el perfil puede ayudar a identificar necesidades, fortalezas, ritmos, patrones de interacción y posibles riesgos. Su uso responsable exige reconocer que ningún perfil agota la complejidad del estudiante.

El perfil académico recoge información sobre la trayectoria, el rendimiento, los créditos aprobados, las asignaturas cursadas, el historial de evaluación y los resultados recientes, lo que permite identificar, en función de las evidencias derivadas, avances, rezagos, dificultades recurrentes o cambios en el rendimiento. El perfil puede ser de utilidad para las tutorías, la planificación de apoyos y la orientación curricular.



Figura 11. Perfil analítico del estudiante virtual.

El perfil de participación describe la forma en que el estudiante interactúa con el entorno virtual. Incluye regularidad de acceso, consulta de recursos, participación en foros, entregas, asistencia a sesiones, mensajes y uso de retroalimentación. Este perfil permite observar estilos de vinculación con el curso. Algunos estudiantes participan intensamente en foros; otros trabajan de manera más autónoma; otros muestran actividad intermitente. La personalización requiere distinguir estas formas sin jerarquizarlas automáticamente.

El perfil de rendimiento se construye a partir de calificaciones, resultados por actividad, desempeño por competencia, intentos en evaluaciones y errores frecuentes. Su valor radica en orientar retroalimentación y recursos específicos. Un estudiante puede requerir apoyo conceptual, práctica adicional, mejora en lectura de consignas o estrategias de organización. Learning Analytics puede ayudar a detectar

patrones de error, pero la interpretación pedagógica define qué tipo de intervención corresponde.

El perfil de riesgo combina señales de bajo desempeño, desconexión, retrasos, historial académico, poca interacción o disminución de actividad. Puede ser útil para priorizar tutorías, pero requiere máxima prudencia. El riesgo no es una identidad, sino una condición temporal que puede cambiar. La clasificación debe abrir oportunidades de apoyo, no producir estigmatización. Además, los modelos pueden generar falsos positivos y falsos negativos, por lo que siempre deben ser revisados por actores humanos.

El perfil de aprendizaje intenta aproximarse a necesidades, preferencias, estrategias, autorregulación y formas de interacción con recursos. En educación virtual, puede incluir patrones de uso de materiales, secuencias de estudio, respuesta a retroalimentación o elección de actividades. No debe confundirse con categorías rígidas de estilos de aprendizaje. La evidencia disponible permite observar comportamientos y tendencias, pero no determina de forma definitiva cómo aprende una persona. El perfil debe ser una hipótesis de trabajo, no una definición cerrada.

El perfil socioeducativo, tecnológico y motivacional resulta indispensable para evitar interpretaciones injustas. Condiciones de conectividad, disponibilidad de dispositivos, carga laboral, responsabilidades familiares, salud emocional, pertenencia cultural o capital académico familiar pueden influir en la participación. Si estos elementos se ignoran, un estudiante con dificultades estructurales puede aparecer simplemente como poco comprometido. La personalización ética requiere comprender el contexto para ofrecer apoyos adecuados.

El perfilado también plantea riesgos de reducción. Cuando una institución convierte datos en categorías, puede simplificar la trayectoria del estudiante y condicionar las expectativas docentes. Las políticas de protección de datos en Learning Analytics proponen separar análisis e intervención para reducir daños y ofrecer garantías a estudiantes y personal académico [21]. Esta lógica resulta útil para la práctica del perfilado: analizar patrones no debería justificar automáticamente decisiones individuales sin mediación, transparencia y posibilidad de revisión.

En pocas palabras, el perfil del estudiante puede potenciar la personalización si se emplea como elemento que aporta a la comprensión y al seguimiento, su potencial depende de que el perfil sea dinámico, contextual, transparente y revisado. En entornos virtuales, el perfil debería facilitar la formulación de mejores preguntas sobre el recorrido del estudiante, y no encasillarlo en un tipo o un nivel.

Segmentación de estudiantes mediante analíticas

La segmentación de estudiantes mediante analíticas consiste en agrupar trayectorias, comportamientos o perfiles con características similares para orientar decisiones pedagógicas e institucionales. En entornos virtuales de Educación Superior, esta práctica puede ayudar a identificar grupos que requieren apoyo diferenciado, estudiantes con avance sostenido, participantes intermitentes, casos de desconexión o patrones de riesgo. Su utilidad depende de que la segmentación no se convierta en clasificación rígida, sino en una herramienta para comprender necesidades y diseñar intervenciones.

Tabla 8. Segmentos estudiantiles según patrones analíticos.

Segmento	Patrón observable	Necesidad y apoyo recomendado
Autónomo	Mantiene buen rendimiento, entrega actividades a tiempo, revisa recursos y avanza de su autonomía. Se recomienda ofrecer materiales de forma constante en el curso complementarios, proyectos de ampliación o virtual.	Necesita retos académicos adicionales, recursos que fortalezcan actividades de profundización y actividades que fortalezcan roles de apoyo en actividades colaborativas.
Participativo	Interviene con frecuencia en foros, debates, actividades grupales y espacios de interacción con docentes o compañeros.	Necesita mantener su motivación y canalizar su participación hacia aprendizajes significativos. Se recomienda proponer actividades colaborativas, debates guiados y retroalimentación que fortalezca la calidad de sus aportes.
Intermitente	Presenta accesos irregulares, alterna periodos de actividad con inactividad y puede entregar algunas tareas fuera de plazo.	Necesita seguimiento preventivo y apoyo en la organización del tiempo. Se recomienda enviar recordatorios, revisar posibles dificultades y orientar una ruta clara de recuperación.
Desconectado	Registra baja conexión al EVA, poca o nula participación, ausencia en sesiones y escaso acceso a recursos.	Necesita contacto temprano para identificar causas de desconexión. Se recomienda verificar situaciones personales, y ofrecer acompañamiento flexible.
Rezagado	Tiene bajo avance en módulos, tareas pendientes, actividades incompletas o retraso frente al ritmo esperado del curso.	Necesita apoyo académico focalizado para recuperar el progreso. Se recomienda priorizar actividades esenciales, ofrecer recursos de refuerzo y establecer un plan breve de recuperación.
En riesgo académico	Combina bajo rendimiento, entregas atrasadas, participación y resultados insuficientes en evaluaciones.	Necesita intervención inmediata para evitar reprobación o abandono. Se recomienda activar alerta temprana, derivar a tutoría académica y realizar seguimiento continuo del caso.
Con necesidad de tutoría	Presenta dudas recurrentes, solicitudes de ayuda, bajo desempeño en temas específicos o dificultades para comprender instrucciones y contenidos.	Necesita acompañamiento personalizado. Se recomienda programar tutorías, revisar las principales dificultades y ofrecer retroalimentación clara con actividades de refuerzo.

El agrupamiento por comportamiento académico puede considerar regularidad de conexión, entrega de actividades, interacción con recursos, participación en foros, desempeño y respuesta a retroalimentación. A partir de estos datos pueden emerger grupos con ritmos distintos: estudiantes constantes, estudiantes intensivos antes de entregas, estudiantes de baja actividad, estudiantes con participación social alta o estudiantes con buen desempeño pese a poca visibilidad en plataforma. Estos grupos no deben interpretarse como tipos fijos de estudiante, sino como patrones situados en un curso y un periodo determinados.

La segmentación por riesgo se orienta a priorizar apoyos. Puede agrupar estudiantes según probabilidad de reprobación, abandono, desconexión o bajo desempeño. Los modelos de predicción académica muestran que distintas variables pueden combinarse para estimar rendimiento [17]. La utilidad didáctica de la segmentación depende de la acción que deriva de ella. Reconocer que se tiene un grupo de riesgo sin poder proporcionar tutoría, recursos o ajustes convierte a la analítica pedagógica en una observación pasiva. La segmentación solo tiene sentido si permite mejorar la intervención.

Los clústeres de aprendizaje y patrones de navegación ofrecen otra vía de análisis. Pueden mostrar rutas frecuentes, secuencias de consulta de recursos, momentos de mayor actividad o formas de interacción con actividades. En cursos virtuales masivos se han identificado patrones de compromiso a lo largo del tiempo, lo que demuestra que la participación no es estática y que los estudiantes pueden transitar entre formas distintas de vinculación con el curso [19]. Esta lectura temporal es útil para no reducir la segmentación a una fotografía inicial.

La caracterización de estudiantes autónomos, intermitentes, rezagados o en riesgo puede ser útil como lenguaje operativo, pero debe manejarse con cuidado. Estas categorías simplifican realidades complejas. Un estudiante intermitente puede estar trabajando, cuidando familiares o estudiando fuera de la plataforma. Un estudiante autónomo puede requerir apoyo invisible. Un estudiante en riesgo puede recuperarse con una intervención oportuna.

El uso pedagógico de la segmentación permite diseñar intervenciones diferenciadas. Un grupo con dificultades conceptuales puede requerir recursos de refuerzo; un grupo con baja participación puede necesitar orientación sobre organización del tiempo; un grupo con actividad alta, pero bajo desempeño puede requerir retroalimentación sobre estrategias de estudio; un grupo avanzado puede recibir actividades de ampliación.

La segmentación también puede apoyar decisiones institucionales. Programas con altos niveles de desconexión, asignaturas con patrones repetidos de rezago o cohortes con dificultades específicas pueden activar acciones de rediseño curricular, formación docente o fortalecimiento tutorial. Para ello se requiere articular Learning Analytics con Academic Analytics, evitando que la información quede encerrada en un tablero de curso. La escala de análisis debe corresponder a la decisión que se quiere tomar.

Las cautelas éticas y metodológicas son indispensables. Los grupos analíticos dependen de datos disponibles, variables seleccionadas, modelos aplicados y decisiones de interpretación. Pueden reflejar sesgos históricos, desigualdades de acceso o diseños pedagógicos deficientes. También pueden producir etiquetamiento si se comunican sin cuidado. La institución debe asegurar transparencia, revisión humana, posibilidad de corrección y uso proporcional de la información.

En síntesis, la segmentación a partir de analíticas puede ser una herramienta para avanzar hacia la personalización del aprendizaje en cuanto se use para dar orientaciones y comprender trayectorias de aprendizaje. La clave es que su sentido no es clasificar a los estudiantes, sino reconocer patrones que permitan actuar de una forma más pertinente. Una segmentación responsable ha de ser dinámica, contextualizada y revisable.

Calidad, validez y gobernanza de los datos educativos

La calidad, validez y gobernanza de los datos educativos son condiciones indispensables para que Learning Analytics pueda sostener decisiones pedagógicas e institucionales confiables. Una universidad puede disponer de grandes volúmenes de datos y, aun así, producir interpretaciones débiles si esos datos están incompletos, desactualizados, fragmentados o mal definidos. En Educación Superior virtual, donde la personalización del aprendizaje depende de señales oportunas, la calidad del dato no es un asunto técnico menor; es una condición de equidad.

La calidad del dato incluye integridad, consistencia, actualidad, precisión y pertinencia. La integridad se refiere a que los registros estén completos. La consistencia exige que los datos mantengan criterios comunes entre sistemas. La actualidad indica que la información esté disponible a tiempo para intervenir. La precisión se relaciona con la fidelidad del registro.

Tabla 9. Criterios para la calidad, validez y gobernanza de los datos educativos.

Criterio	Pregunta orientadora	Aplicación en Learning Analytics
Compleitud	¿Los datos están completos o existen vacíos importantes?	Evita tomar decisiones con registros incompletos sobre asistencia, entregas, calificaciones o participación.
Actualización	¿La información corresponde al periodo académico vigente?	Permite que las alertas y reportes reflejen la situación real del estudiante.
Consistencia	¿Los datos coinciden entre plataformas y sistemas académicos?	Reduce errores cuando se integran datos del aula virtual, sistema de notas y tutorías.
Pertinencia	¿El dato realmente aporta al análisis del aprendizaje?	Evita usar métricas superficiales que no explican el desempeño o la participación.
Validez pedagógica	¿El indicador mide lo que realmente se quiere observar?	Impide interpretar clics, tiempo conectado o accesos como aprendizaje directo.
Privacidad	¿Se protege la información personal y académica del estudiante?	Garantiza un uso responsable de datos sensibles dentro de la institución.
Transparencia	¿Los estudiantes y docentes conocen qué datos se usan y con qué finalidad?	Fortalece la confianza y evita percepciones de vigilancia.
Responsabilidad	¿Quién valida, interpreta y actúa sobre los datos?	Asegura que las decisiones no dependan únicamente de sistemas automáticos.
Equidad	¿Los datos pueden reproducir sesgos o afectar injustamente a ciertos estudiantes?	Ayuda a prevenir etiquetamientos negativos o decisiones discriminatorias.
Gobernanza institucional	¿Existen normas, roles y protocolos para gestionar los datos?	Organiza el acceso, uso, seguridad, interpretación y evaluación de los datos educativos.

Los datos incompletos o erróneos pueden afectar decisiones. Si un sistema no registra actividades realizadas fuera del LMS, el estudiante puede aparecer como inactivo. Si una calificación no se sincroniza, el modelo puede estimar riesgo de manera incorrecta. Si se mezclan cursos con diseños muy distintos, los indicadores pueden perder sentido. La investigación sobre ruido en atributos muestra que la calidad de las variables afecta el desempeño de modelos automatizados en escenarios auténticos de aprendizaje [16]. Esta evidencia refuerza la necesidad de revisar datos antes de utilizarlos para decisiones sobre estudiantes.

La validez de los indicadores también es uno de los elementos centrales ya que un indicador es válido cuando representa de un modo razonable la realidad del fenómeno que queremos observar. Un conteo de clics, por ejemplo, no necesariamente nos está midiendo aprendizaje, una cifra de tiempo de conexión no mide dedicación, una cifra de participación en foros no mide colaboración. La validez irá en relación del dato y el diseño pedagógico y del objetivo de análisis, en Learning

Analytics, un mal indicador puede ser el responsable de una intervención mal orientada.

La gobernanza de datos establece reglas, responsabilidades y procesos para el uso de la información educativa. Incluye políticas de acceso, seguridad, calidad, almacenamiento, integración, privacidad, transparencia, auditoría y eliminación de datos. La literatura sobre gobernanza de datos para Learning Analytics identifica factores críticos como propiedad de los datos, calidad, acceso, roles institucionales y alineación con objetivos educativos [22]. Sin gobernanza, las analíticas pueden depender de iniciativas aisladas, criterios informales o decisiones opacas.

La arquitectura institucional de datos también forma parte de la gobernanza. Reorganizar datos para investigadores, docentes y tomadores de decisión requiere colaboración entre áreas académicas, técnicas y administrativas[18]. Gracias a esta colaboración, se pueden confeccionar conjuntos de datos, documentados y reutilizables. La integración ha de ser proporcional ya que no toda la información disponible tiene que estar conectada.

La protección de datos personales atraviesa todo el proceso. Learning Analytics trabaja con información que puede revelar desempeño, hábitos, dificultades, participación, contexto y riesgo. Un marco de protección de datos para analíticas del aprendizaje propone distinguir procesos de análisis e intervención, de modo que la búsqueda de patrones no se traduzca automáticamente en decisiones individuales sin garantías [21].

La gobernanza también debe abordar sesgos y responsabilidades. Los datos pueden reflejar desigualdades previas, brechas tecnológicas, condiciones socioeconómicas o prácticas docentes heterogéneas. Si estos elementos no se consideran, los modelos pueden reforzar inequidades. La institución debe definir quién valida indicadores, quién autoriza modelos, quién revisa alertas, quién interviene y cómo se evalúa el impacto de las acciones. La responsabilidad no puede delegarse por completo al sistema.

Para resumir, se puede afirmar que la calidad, la validez y la gobernanza de los datos educativos son los parámetros que establecen la fiabilidad de Learning Analytics. El aprendizaje personalizado requiere contar con datos relevantes, indicadores válidos, una infraestructura bien documentada y reglas de uso claras. Learning Analytics sin gobernanza puede derivar en vigilancia o decisiones injustas; con buena gobernanza puede ser una práctica de acompañamiento, equidad y mejora institucional.

Sección 4

Modelos de personalización del aprendizaje basados en analíticas

Modelos descriptivos para la personalización

Los modelos descriptivos constituyen el primer nivel de uso de Learning Analytics para personalizar el aprendizaje en entornos virtuales de Educación Superior. Su función principal no es predecir ni recomendar, sino representar de manera comprensible lo que ocurre durante el proceso formativo: participación en la plataforma, avance en actividades, interacción con recursos, resultados parciales, tiempos de entrega, uso de materiales, participación en foros y trayectorias de navegación. En este nivel, la personalización comienza con una pregunta sencilla y exigente: qué se puede conocer del proceso de aprendizaje a partir de los registros disponibles sin confundir actividad digital con comprensión académica.




Figura 12. Modelos descriptivos para la personalización del aprendizaje

Un tablero descriptivo puede mostrar accesos, clics o permanencia en un recurso, pero esos datos aislados no explican por qué un estudiante avanza, se detiene o cambia su ritmo. La literatura sobre personalización apoyada en analíticas ha propuesto marcos como PERLA, que integra objetivos del aprendiz, contexto, datos,

indicadores y acciones para diseñar ambientes personalizados desde una perspectiva centrada en el estudiante [23].

En la práctica universitaria, los modelos descriptivos suelen expresarse en reportes, visualizaciones, paneles de seguimiento y resúmenes de curso. Pueden apoyar al docente en la identificación de estudiantes con baja participación, grupos con dificultad en una actividad, recursos poco consultados o momentos del curso donde se acumulan retrasos. También pueden ayudar al estudiante a reconocer su propio ritmo de estudio, comparar su avance con metas esperadas y tomar decisiones de autorregulación.

La efectividad de estos tableros, sin embargo, depende de que la información sea clara, interpretable y accionable; los estudios sobre dashboards de Learning Analytics muestran que su diseño debe considerar comprensión, utilidad percibida y capacidad para orientar cambios en el comportamiento de aprendizaje [24].

No hay que presentar un modelo descriptivo como una afirmación que hable de la totalidad del estudiante, la existencia de una baja frecuencia de acceso podría corresponder a una escasa conexión, un modo de trabajo sin conexión, un uso de materiales descargados, una inadecuación personal o una serie de problemas de navegación. Pero también una alta actividad no es sinónimo del aprendizaje más profundo y profundo, precisamente por ello se entiende la importancia de la descripción en que pueda abrir un proceso de conversación pedagógica y no cerrar un juicio. El docente necesita leer los datos como las señales primarias que se necesitan contrastar con la evaluación, la comunicación directa, la tutoría y el conocimiento del contexto.

La personalización descriptiva puede organizarse en tres niveles:

1. **Individual:** muestra al estudiante su avance, sus entregas, su participación y su relación con las metas del curso.
2. **Docente:** permite observar patrones del grupo, dificultades recurrentes y necesidad de ajustes didácticos.
3. **Institucional:** ofrece evidencia para revisar cursos, servicios de apoyo, permanencia y calidad académica.

Estos niveles no deben mezclarse sin cuidado, porque una métrica diseñada para orientar al estudiante puede ser inadecuada para evaluar docentes o tomar decisiones administrativas. El principal aporte de los modelos descriptivos es convertir datos dispersos en evidencias comprensibles. Cuando se diseñan con

criterio educativo, permiten iniciar intervenciones tempranas, ajustar recursos, modular cargas de trabajo y mejorar la retroalimentación, su límite aparece cuando la institución los usa como vigilancia o como ranking simplificado.

Modelos predictivos de desempeño y riesgo académico

Los modelos predictivos amplían el alcance de Learning Analytics al estimar la probabilidad de ciertos eventos académicos antes de que ocurran o antes de que sean irreversibles. En entornos virtuales de Educación Superior, suelen aplicarse para anticipar riesgo de reprobación, abandono, baja participación, retraso sostenido, desempeño insuficiente o necesidad de apoyo tutorial. Su interés pedagógico está en la oportunidad: detectar señales tempranas puede permitir que la institución actúe antes de que el estudiante pierda contacto con el curso o acumule dificultades difíciles de revertir.




Figura 13. Modelo predictivo de riesgo académico.

La predicción se construye a partir de variables observables, como actividad en plataforma, entregas, resultados parciales, interacción con recursos, participación en foros, trayectoria académica previa o patrones de uso del curso. Estudios sobre sistemas de alerta temprana han mostrado que el uso categorizado de recursos del curso puede mejorar la comprensión de patrones asociados al riesgo académico [25]. Esta evidencia resulta relevante porque desplaza la mirada de una métrica única hacia combinaciones de señales que han de entenderse dentro del diseño del curso.

Puede calcular probabilidades, ordenar casos o sugerir prioridades, pero no conoce por sí mismo las causas de una trayectoria. Un estudiante puede aparecer en riesgo

por problemas de conectividad, salud, carga laboral, desorientación académica, dificultades de lectura o baja adaptación al entorno virtual. La construcción de modelos predictivos exige decisiones técnicas y éticas. Es necesario definir qué evento se predice, con qué datos, en qué momento del curso, con qué nivel de precisión, quién recibe la alerta y qué acciones se activan.

También se deben revisar sesgos, falsos positivos, falsos negativos y efectos no deseados. Las recomendaciones prácticas para el uso ético de analíticas predictivas en educación a distancia insisten en involucrar a usuarios finales, considerar necesidades diversas, actuar sobre los datos y revisar sesgos ocultos mediante trabajo interdisciplinario [26]. Estos criterios son esenciales para que la predicción sirva a la equidad y no a la clasificación punitiva.

En términos de personalización, los modelos predictivos permiten diferenciar apoyos. Un estudiante con riesgo por baja participación puede requerir contacto tutorial; otro con bajo desempeño en evaluaciones puede necesitar recursos de refuerzo; otro con retrasos frecuentes puede beneficiarse de orientación en gestión del tiempo. La misma probabilidad de riesgo puede esconder necesidades distintas, de modo que el modelo debe conectarse con protocolos de intervención flexibles. Personalizar no significa enviar el mismo mensaje automático a todos los casos marcados por el sistema, sino ajustar el tipo de apoyo a la naturaleza probable de la dificultad.

La eficacia de la predicción no debe juzgarse sólo en función de criterios de exactitud estadística ni sólo en función de que un modelo pueda ser estadísticamente correcto, el único criterio institucional a tener en cuenta no es el número de alertas generadas, sino el número de alertas generadas que se convierten en acompañamiento de la trayectoria, en mejoras realmente efectivas de la trayectoria estudiantil. Desde la óptica de Learning Analytics, predecir tiene proyección institucional si se abre la posibilidad de acompañar y cuidar académicamente.

Modelos prescriptivos y sistemas de recomendación

Los modelos prescriptivos representan un nivel más exigente de personalización porque no se limitan a describir o anticipar, sino que sugieren acciones. En Educación Superior virtual, pueden recomendar recursos, actividades, rutas de estudio, ejercicios de refuerzo, pares de colaboración, momentos de repaso o intervenciones tutoriales. Su propósito no es decidir por el estudiante ni por el docente, sino ofrecer opciones pertinentes a partir de evidencias del proceso de aprendizaje. Una

recomendación educativa válida debe estar vinculada con objetivos formativos, necesidades detectadas y posibilidades reales de acción.

Los sistemas de recomendación aplicados al aprendizaje toman inspiración de entornos digitales donde se sugieren contenidos según perfiles, historial o preferencias. En educación, esa lógica debe ser más cuidadosa porque recomendar un recurso no equivale a recomendar una película o un producto. La recomendación afecta oportunidades de aprendizaje, distribución de apoyo y percepción que el estudiante tiene sobre sus propias capacidades. La plataforma RiPPLE, por ejemplo, combina recomendación adaptativa y actividades generadas por la comunidad de aprendizaje para apoyar la identificación de recursos y preguntas pertinentes, con resultados iniciales positivos en percepción y desempeño [27].




Figura 14. Modelo prescriptivo para la personalización del aprendizaje.

Una prescripción educativa puede basarse en distintos criterios. Puede sugerir un recurso porque el estudiante falló en un concepto, porque otros estudiantes con trayectorias similares lo usaron con buenos resultados, porque el diseño instruccional lo ubica como apoyo previo a una actividad o porque el propio estudiante declaró una meta de aprendizaje.

Una recomendación únicamente fundamentada en similitudes estadísticas puede llegar a ser útil, pero también puede reproducir patrones de desigualdad o encerrar al estudiante en caminos estrechos. Una recomendación relacionada con objetivos pedagógicos tiene más posibilidades de sostener un aprendizaje significativo.

La personalización prescriptiva exige transparencia. El estudiante debería comprender por qué recibe una recomendación, qué problema intenta atender y cómo puede decidir si la usa. El docente, por su parte, necesita conocer los criterios del sistema para no delegar su responsabilidad pedagógica en una salida algorítmica. Los marcos que articulan personalización y analíticas insisten en que las acciones deben derivarse de objetivos claros, indicadores pertinentes y mecanismos de retroalimentación que permitan ajustar el proceso [23]. Sin esa articulación, la recomendación se vuelve una automatización opaca.

Si cada estudiante recibe una ruta completamente distinta, puede perderse el sentido de comunidad, la discusión compartida y la garantía de resultados de aprendizaje comunes. La personalización universitaria debe equilibrar adaptación y proyecto académico colectivo: variar recursos, apoyos y ritmos sin fragmentar los criterios de calidad ni reducir la exigencia intelectual. Un sistema de recomendación no debe empobrecer el currículo para estudiantes con dificultades, sino ofrecer caminos de acceso, refuerzo y profundización.

La valía de los modelos prescriptivos reposa en la importancia de las acciones que expresa o la posibilidad de contrastar sus efectos, cosa que una recomendación debe posibilitar, pues debe poder ser aceptada, rechazada, actualizada o debatida. Una recomendación tiene que producir también evidencias de su valencia: si el alumno la utilizó, si eso le supuso una mejora, si esto le supuso un aumento del nivel de comprensión o si esto le supuso un aumento del nivel de autorregulación o, en su lugar, de sobrecarga. La prescripción educativa responsable no es una orden algorítmica, constituye una mediación que amplía opciones de aprendizaje.

Personalización de contenidos y recursos educativos

La personalización de contenidos y recursos educativos busca ajustar materiales, ejemplos, actividades de apoyo y rutas de consulta a las necesidades del estudiante sin alterar arbitrariamente los resultados de aprendizaje del curso. En entornos virtuales universitarios, esta personalización puede manifestarse en lecturas complementarias, videos de refuerzo, simuladores, ejercicios graduados, bancos de preguntas, recursos multimedia, guías de estudio o materiales de profundización. Su finalidad es ampliar las posibilidades de acceso al conocimiento, no convertir el curso en una sucesión de contenidos aislados.

Learning Analytics puede apoyar esta tarea al identificar patrones de uso y dificultad. Si muchos estudiantes abandonan una actividad después de consultar un recurso específico, si un grupo presenta errores recurrentes en un concepto o si ciertos

materiales se asocian con mejores desempeños posteriores, el docente cuenta con evidencia para revisar, reorganizar o complementar el curso. El marco PERLA concibe la personalización como una convergencia entre metas del aprendiz, datos, indicadores y acciones, lo cual permite pensar los recursos no como objetos estáticos, sino como mediaciones ajustables según evidencias del proceso [23].

La adecuación de materiales puede desarrollarse a través de distintas vías, una vía remedial proporciona ayudas cuando surgen lagunas previas; una vía de profundización introduce recursos más elaborados para estudiantes que progresan con solvencia; una vía contextual presenta ejemplos próximos a la disciplina, al programa o al campo profesional; una vía de accesibilidad adapta formatos para estudiantes con necesidades específicas. En todos los casos la analítica debe estar subordinada al diseño pedagógico. No se trata de ofrecer más materiales, sino de seleccionar aquellos recursos que den respuesta a una necesidad detectada.

Los datos de uso de recursos requieren lectura cautelosa. Un recurso poco consultado puede ser irrelevante, difícil de encontrar, mal integrado a la actividad o innecesario para quienes ya dominan el tema. Un recurso muy consultado puede ser valioso, pero también puede indicar confusión o dependencia excesiva. La personalización de contenidos no puede apoyarse solo en frecuencia de acceso; necesita relacionar uso, desempeño, secuencia didáctica, retroalimentación y percepción estudiantil. En este punto, el vínculo entre diseño de aprendizaje y analíticas es decisivo, porque los datos solo son interpretables cuando se conoce la intención pedagógica del curso [28].

La personalización de recursos también puede favorecer la equidad si atiende brechas de ingreso, diversidad de trayectorias y ritmos de estudio. En programas virtuales de Educación Superior, algunos estudiantes necesitan materiales introductorios para nivelar conocimientos, mientras otros requieren desafíos adicionales para sostener motivación. La analítica permite detectar necesidades diferenciadas, pero la respuesta debe evitar rutas deficitarias que encasillen a ciertos estudiantes en contenidos simplificados. Personalizar implica ofrecer apoyos sin reducir expectativas académicas.

Una estrategia sólida combina curaduría docente, evidencia de uso, criterios de accesibilidad y evaluación continua. Los recursos recomendados deben ser pertinentes, actualizados, comprensibles y conectados con actividades evaluables. También deben conservar trazabilidad: qué recurso se recomendó, por qué, cuándo, a quién y con qué resultado. De esa manera, la personalización de contenidos deja de

ser una decisión intuitiva o una lista extensa de materiales y se convierte en una práctica pedagógica informada por datos.

Personalización de la evaluación y retroalimentación

La personalización de la evaluación y la retroalimentación constituye uno de los usos más sensibles de Learning Analytics, porque incide directamente en la manera en que el estudiante comprende su avance, reconoce sus errores y toma decisiones para mejorar. En educación virtual, la evaluación suele dejar registros abundantes: respuestas, intentos, tiempos, entregas, rúbricas, comentarios, calificaciones parciales, revisiones entre pares y participación en actividades formativas. Estos datos pueden enriquecer la retroalimentación si se interpretan desde criterios pedagógicos claros.

Tabla 10. Personalización de la evaluación y retroalimentación mediante Learning Analytics.

Aspecto	Uso de los datos	Acción pedagógica
Evaluación formativa	Analizar respuestas, intentos, errores frecuentes y resultados parciales.	Identificar dificultades antes de la evaluación final y ofrecer apoyo oportuno.
Tipo de error	Diferenciar si el problema es conceptual, procedimental, de argumentación o de comprensión de instrucciones.	Dar retroalimentación específica según la dificultad real del estudiante.
Seguimiento del avance	Revisar entregas, calificaciones parciales, tiempos e historial de participación.	Orientar al estudiante sobre qué ha logrado, qué le falta y cómo puede mejorar.
Retroalimentación personalizada	Usar evidencias del desempeño individual para ajustar los comentarios.	Emitir mensajes claros, comprensibles y accionables, no solo señalar una nota baja.
Recomendación de recursos	Relacionar errores o bajos resultados con materiales de apoyo.	Sugerir lecturas, ejercicios, tutorías o recursos de refuerzo según la necesidad detectada.
Ajuste de rúbricas o consignas	Detectar actividades que generan confusión o errores recurrentes en varios estudiantes.	Revisar instrucciones, criterios de evaluación o diseño de la actividad.
Alertas académicas	Identificar tareas no entregadas, intentos fallidos o baja participación.	Activar acompañamiento docente, tutoría o intervención temprana.
Cuidado ético	Evitar comparaciones injustas, etiquetas fijas o visualizaciones que generen ansiedad.	Presentar la retroalimentación como oportunidad de mejora y no como sanción.

Personalizar la evaluación no significa modificar los estándares para cada estudiante ni hacer que cada quien sea evaluado con reglas distintas. Significa ofrecer evidencias y orientaciones ajustadas al proceso seguido, al tipo de error, al nivel de avance y a las decisiones que el estudiante puede tomar.

Dos estudiantes con la misma calificación pueden necesitar retroalimentaciones distintas: uno puede comprender el concepto, pero fallar en la argumentación; otro puede presentar dificultades de base que requieren apoyo previo. Learning Analytics permite observar esas diferencias cuando integra resultados, secuencias, intentos y patrones de interacción.

La retroalimentación personalizada debe ser comprensible, específica y accionable. No basta con indicar que el desempeño fue bajo o que una competencia está en desarrollo; el estudiante necesita saber qué hizo, qué falta, por qué importa y cómo puede avanzar. Investigaciones recientes sobre herramientas de analítica de retroalimentación subrayan la importancia de fortalecer la alfabetización en feedback, es decir, la capacidad del estudiante para interpretar, valorar y usar la retroalimentación en su aprendizaje [29]. Su uso desde esta perspectiva tiene una especial utilidad en contextos concretos. Es relevante en los entornos virtuales donde la distancia podría fácilmente llevar a considerar los propios comentarios como información aislada, como un conjunto de información no relacionada con la interacción pedagógica.

La utilización de esta perspectiva tiene una especial utilidad en contextos concretos. Es especialmente relevante en el caso de entornos virtuales donde la distancia podría fácilmente llevar a considerar los propios comentarios como información aislada, como un conjunto de información no relacionada con la interacción pedagógica. Los modelos analíticos pueden apoyar la evaluación formativa mediante detección de errores frecuentes, agrupamiento de respuestas, seguimiento de intentos, comparación de avances y generación de alertas sobre tareas no entregadas. También pueden orientar al docente para ajustar rúbricas, revisar consignas o identificar actividades que producen confusión. No solo se personaliza el mensaje hacia el estudiante, sino que también se produce personalización cuando el maestro modifica la evaluación porque los datos reflejan que una consigna, un recurso o secuencia no se hace como se preveía.

Conviene distinguir entre retroalimentación automatizada y retroalimentación pedagógica mediada por datos. La automatización puede ser útil en ejercicios de respuesta cerrada, práctica repetitiva o revisión inicial, pero resulta insuficiente

cuando la tarea exige argumentación, juicio ético, creatividad, escritura académica o integración conceptual. En esos casos, la analítica puede apoyar la lectura docente, no reemplazarla. El riesgo aparece cuando la institución confunde velocidad de respuesta con calidad formativa.

La evaluación personalizada también exige cuidado ético. Los datos de desempeño son sensibles y pueden afectar la confianza del estudiante. Una visualización mal diseñada puede generar ansiedad, comparación injusta o sensación de vigilancia. Por ello, la retroalimentación basada en analíticas debe proteger la dignidad académica del estudiante, evitar etiquetas fijas y presentar la mejora como posibilidad. Evaluar con datos no significa endurecer el control, sino ofrecer evidencias más precisas para aprender mejor.

Tutoría académica apoyada en Learning Analytics

La tutoría académica apoyada en Learning Analytics busca transformar los datos educativos en acompañamiento oportuno. En Educación Superior virtual, la tutoría cumple una función estratégica porque el estudiante puede experimentar aislamiento, desorientación, dificultades para organizar el tiempo o problemas para sostener la participación. Las analíticas permiten identificar señales tempranas de interrupción, bajo desempeño, desconexión o retraso, pero esas señales solo adquieren valor cuando se conectan con un sistema de apoyo humano.

Un modelo tutorial basado en analíticas comienza con indicadores definidos y protocolos claros. La institución debe decidir qué señales activan una alerta, quien la recibe, en cuánto tiempo se revisa, cómo se contacta al estudiante, qué tipo de apoyo se ofrece y cómo se registra la intervención. Los sistemas de alerta temprana han mostrado utilidad al analizar patrones de uso de recursos y categorías de actividad del curso [25]. Sin embargo, la alerta no es la intervención; es apenas la puerta de entrada a una conversación académica.

Tabla 11. Proceso de tutoría académica apoyada en Learning Analytics.

Momento de la tutoría	Señal analítica observada	Acción del tutor
Detección inicial	Baja conexión, entregas tardías, bajo rendimiento o poca participación.	Identificar estudiantes que podrían requerir acompañamiento académico.
Priorización de casos	Combinación de varios factores de riesgo académico.	Determinar qué estudiantes necesitan atención inmediata.
Contacto con el estudiante	Inactividad, ausencia de respuesta o interrupción del avance.	Establecer comunicación directa para conocer la situación real del estudiante.

Momento de la tutoría	Señal analítica observada	Acción del tutor
Diagnóstico tutorial	Dificultades de acceso, organización del tiempo, comprensión de contenidos o desmotivación.	Diferenciar el tipo de necesidad antes de aplicar una intervención.
Orientación académica	Errores frecuentes, bajo desempeño o avance incompleto.	Recomendar recursos, explicar contenidos, proponer tutorías o ajustar estrategias de estudio.
Derivación institucional	Problemas tecnológicos, administrativos, emocionales o de bienestar.	Remitir el caso a soporte técnico, coordinación académica o bienestar estudiantil.
Seguimiento	Cambios en participación, entregas, calificaciones o conexión después de la intervención.	Verificar si el acompañamiento tuvo efecto y ajustar el plan de apoyo.
Cierre o continuidad	Mejora sostenida o persistencia del riesgo académico.	Cerrar el caso, mantener seguimiento o activar nuevas acciones de apoyo.

La tutoría personalizada requiere distinguir tipos de necesidad. Un estudiante con entregas tardías puede necesitar apoyo en planificación; otro con baja actividad puede enfrentar problemas de acceso; otro con evaluaciones débiles puede requerir orientación conceptual; otro con participación irregular puede necesitar acompañamiento emocional o administrativo. Si todos reciben el mismo mensaje automático, la personalización se reduce a una formalidad. El tutor debe contar con información suficiente para priorizar casos, pero también con margen profesional para interpretar la situación.

La ética es central en este tipo de intervención. Los estudiantes deben comprender qué datos se usan, con qué propósito y qué beneficios pueden esperar. Las recomendaciones para el uso ético de analíticas predictivas señalan que las instituciones deben involucrar a docentes y estudiantes, considerar diversidad de necesidades, actuar sobre la información y revisar posibles sesgos [26]. En tutoría, esto implica evitar que el estudiante sea tratado como un expediente de riesgo y reconocerlo como sujeto de decisión sobre su propio proceso.

El diseño institucional de la tutoría debe integrar actores. Docentes, tutores, coordinadores académicos, bienestar estudiantil, soporte tecnológico y gestión curricular pueden intervenir en momentos distintos. Learning Analytics ayuda a distribuir la atención, pero no resuelve por sí sola la capacidad operativa. Si la institución genera alertas sin equipo suficiente, sin formación o sin rutas de derivación, puede producir frustración y desgaste. La personalización requiere infraestructura humana, no solo infraestructura tecnológica.

Una tutoría apoyada en analíticas puede fortalecer la permanencia cuando combina prevención, pertinencia y seguimiento. El contacto debe ser respetuoso, concreto y orientado a opciones de mejora; después, la institución necesita verificar si el apoyo ofrecido tuvo efecto. Así, Learning Analytics deja de funcionar como observación pasiva y se convierte en una herramienta para sostener trayectorias. En educación virtual, acompañar no es vigilar: es reconocer a tiempo que alguien necesita una mediación y ofrecerla con criterio académico.

Diseño instruccional basado en datos

El diseño instruccional basado en datos utiliza evidencias de aprendizaje para revisar, ajustar y mejorar la arquitectura de un curso virtual. No se limita a observar al estudiante; también observa el propio diseño: secuencia de actividades, claridad de consignas, carga de trabajo, pertinencia de recursos, dificultad de evaluaciones, momentos de retroalimentación y coherencia entre objetivos, actividades y resultados. Esta perspectiva evita atribuir todo problema al estudiante y permite reconocer que ciertas dificultades pueden originarse en decisiones didácticas.

Learning Analytics aporta información sobre cómo se comporta el curso cuando es usado por estudiantes reales. Una secuencia puede parecer ordenada en el plan docente y, sin embargo, generar abandono en una actividad, baja consulta de recursos clave o concentración de errores en una evaluación. La relación entre learning design y Learning Analytics ha sido descrita como una relación dinámica y sinérgica, capaz de ofrecer información sumativa, en tiempo real y predictiva para mejorar experiencias digitales de aprendizaje [28]. Este enfoque convierte los datos en insumo para rediseñar, no solo para monitorear.

Tabla 12. Diseño instruccional basado en datos.

Elemento del diseño	Evidencia analítica	Decisión de mejora
Secuencia contenidos	de Abandono o baja actividad en una unidad específica.	Reorganizar el orden de los temas o dividir contenidos complejos en partes más manejables.
Claridad consignas	de Respuestas dispersas, errores repetidos o muchas consultas sobre una misma actividad.	Mejorar instrucciones, agregar ejemplos o precisar criterios de evaluación.
Carga de trabajo	Disminución de participación después de actividades extensas.	Ajustar tiempos, reducir sobrecarga o distribuir mejor las tareas durante el curso.
Recursos educativos	Baja consulta de materiales o revisión repetida sin mejora en el desempeño.	Sustituir, complementar o rediseñar recursos poco claros o insuficientes.

Elemento del diseño	Evidencia analítica	Decisión de mejora
Actividades de aprendizaje	de Bajo cumplimiento, participación superficial o escasa interacción.	Rediseñar actividades para que sean más pertinentes, guiadas y conectadas con los objetivos.
Evaluaciones	Concentración de errores en una pregunta, tarea o prueba.	Revisar el nivel de dificultad, la redacción o la coherencia entre contenidos y evaluación.
Retroalimentación	Mejora limitada después de comentarios o devoluciones docentes.	Hacer la retroalimentación más específica, oportuna y orientada a acciones concretas.
Acompañamiento	Estudiantes con rezago, baja conexión o avance incompleto.	Incorporar tutorías, alertas tempranas o recursos de refuerzo en momentos clave.
Visualización del avance	Dificultad para identificar progreso, pendientes o riesgos.	Crear tableros, reportes simples o mapas de progreso para docentes y estudiantes.
Mejora continua	Comparación entre resultados esperados y resultados reales del curso.	Ajustar el diseño instruccional en cada periodo académico con base en evidencias.

El rediseño instruccional puede apoyarse en distintos indicios. Si muchos estudiantes revisan repetidamente un material antes de fallar en una tarea, quizá el recurso no explica lo necesario. Si la participación cae después de una actividad extensa, puede existir sobrecarga. Si una consigna produce respuestas muy dispersas, tal vez requiere mayor claridad o ejemplos. Si un foro recibe mensajes superficiales, quizá la pregunta no exige elaboración o no está conectada con la evaluación. La analítica ofrece señales, pero el juicio didáctico decide qué ajuste corresponde.

Los tableros descriptivos pueden ayudar al docente a revisar el curso en tiempo de ejecución. Cuando la información es comprensible y oportuna, permite corregir antes del cierre: abrir una tutoría, grabar una explicación adicional, redistribuir fechas, aclarar criterios o proponer ejercicios de práctica. Los estudios sobre dashboards muestran que su efectividad depende de que el usuario pueda interpretar la información y convertirla en decisiones de aprendizaje [24]. Para el diseño instruccional, esto significa que una visualización útil no es la más compleja, sino la que ayuda a decidir qué cambiar.

El diseño basado en datos no debe conducir a una pedagogía reactiva permanente. No todo ajuste debe hacerse por una fluctuación de métricas, ni todo comportamiento visible exige modificación. El curso necesita estabilidad, coherencia y exigencia académica. Los datos sirven para identificar patrones relevantes, no para improvisar el currículo cada semana. Una práctica madura combina planificación previa, seguimiento durante el curso y revisión posterior para mejorar futuras cohortes.

La personalización se fortalece cuando el diseño instruccional incorpora rutas de apoyo desde el inicio. En lugar de esperar a que los datos muestren dificultades, el curso puede prever recursos alternativos, actividades diagnósticas, retroalimentación escalonada y momentos de tutoría. Luego, Learning Analytics permite ajustar esos apoyos según el comportamiento real del grupo. Diseñar con datos no significa diseñar para el promedio, sino construir cursos capaces de responder a trayectorias diversas sin perder unidad académica.

Integración de inteligencia artificial en la personalización

La integración de inteligencia artificial en la personalización del aprendizaje amplía las capacidades de Learning Analytics, pero también aumenta sus riesgos. En Educación Superior virtual, la IA puede apoyar clasificación de perfiles, predicción de desempeño, recomendación de recursos, análisis de textos, tutoría automatizada, evaluación asistida, generación de retroalimentación y adaptación de rutas de aprendizaje. Estas posibilidades deben entenderse como mediaciones técnicas dentro de un proyecto pedagógico, no como sustitución del diseño docente ni de la responsabilidad institucional.

Tabla 13. Aplicaciones de IA en la personalización del aprendizaje.

Aplicación de IA	Uso y beneficio educativo	Riesgo y control humano
Chatbot académico	Atiende preguntas frecuentes sobre contenidos, actividades, fechas, instrucciones y uso del EVA. Facilita apoyo inmediato y reduce tiempos de respuesta.	Puede entregar respuestas incompletas o fuera de contexto. El docente debe revisar su configuración, actualizar la información y supervisar consultas críticas.
Recomendador de recursos	Sugiere lecturas, videos, ejercicios o materiales de refuerzo según desempeño y avance del estudiante. Favorece la personalización del aprendizaje.	Puede recomendar recursos poco pertinentes o reforzar rutas limitadas. El docente debe validar que los materiales respondan a los objetivos del curso.
Predicción de riesgo	Identifica estudiantes con posible bajo rendimiento, desconexión o riesgo de abandono mediante datos de notas, accesos, entregas y participación. Permite activar alertas tempranas.	Puede generar clasificaciones erróneas o etiquetar al estudiante. Toda predicción debe ser revisada por el docente, tutor o coordinación académica antes de intervenir.
Retroalimentación automática	Ofrece comentarios inmediatos en cuestionarios, ejercicios o actividades estructuradas. Ayuda al estudiante a corregir errores de forma oportuna.	Puede ser genérica o no captar procesos complejos de aprendizaje. El docente debe complementar la retroalimentación en tareas abiertas o de mayor profundidad.
Análisis de textos	Analiza respuestas abiertas, ensayos, foros o comentarios para identificar temas, dudas frecuentes, calidad argumentativa o necesidades de resultados.	Puede interpretar mal el sentido del texto o ignorar el contexto del estudiante. El docente debe revisar los resultados antes de emitir juicios académicos.

Aplicación de IA	Uso y beneficio educativo	Riesgo y control humano
Generación de alertas	Produce avisos sobre baja conexión, tareas pendientes, bajo rendimiento, alarmas injustificadas. Facilita seguimiento oportuno.	Puede generar exceso de alertas o decisiones académicas injustificadas. El equipo académico debe definir criterios claros y validar cada alerta antes de tomar decisiones.

La literatura sobre aplicaciones de inteligencia artificial en Educación Superior muestra una presencia creciente de sistemas de tutoría inteligente, evaluación automatizada, sistemas adaptativos y analíticas predictivas, aunque también advierte que muchas investigaciones se centran más en la dimensión técnica que en la perspectiva de los educadores [30]. Esta advertencia es relevante para el presente libro: la personalización no puede definirse solo desde la capacidad algorítmica, porque involucra currículo, ética, equidad, interacción pedagógica y sentido de formación universitaria.

La IA puede mejorar la personalización cuando ayuda a procesar información que sería difícil de manejar manualmente. Puede detectar patrones en grandes volúmenes de datos, agrupar respuestas abiertas, identificar errores frecuentes, sugerir recursos o priorizar casos de tutoría. También puede apoyar sistemas de recomendación como RiPPLE, donde la adaptación se vincula con actividades, recursos y participación de la comunidad de aprendizaje [27]. El valor de estas aplicaciones depende de que las recomendaciones sean explicables, revisables y alineadas con objetivos educativos.

El uso de IA en personalización exige evitar determinismos. Un modelo puede inferir probabilidades, pero no debe definir el potencial académico de una persona. Puede sugerir una ruta, pero no debe cerrar alternativas. Puede apoyar retroalimentación, pero no sustituir la comprensión docente de tareas complejas. En Educación Superior, aprender implica argumentar, investigar, crear, contrastar fuentes, tomar decisiones éticas y participar en comunidades académicas; ninguna de estas dimensiones puede reducirse a una salida automática.

La transparencia y la gobernanza son condiciones mínimas. La institución debe definir qué sistemas usa, qué datos procesan, con qué finalidad, cómo se evalúan, qué sesgos pueden producir y qué mecanismos de apelación existen. También debe formar a docentes y estudiantes para comprender límites y posibilidades de la IA. La personalización apoyada en inteligencia artificial pierde legitimidad si opera como caja negra, si clasifica sin explicación o si desplaza responsabilidades hacia un sistema que nadie puede auditar.

Integrar IA de manera responsable significa colocarla al servicio de la personalización pedagógica, no de la automatización indiscriminada. Sus mejores usos aparecen cuando libera tiempo para la mediación humana, mejora la oportunidad de los apoyos, amplía opciones de aprendizaje y permite comprender trayectorias complejas. Sus peores usos aparecen cuando simplifica al estudiante, reproduce sesgos o convierte la educación virtual en una experiencia de vigilancia predictiva. La pregunta central no es cuánta inteligencia artificial puede incorporarse, sino qué decisiones educativas mejora y bajo qué condiciones éticas.

SECCIÓN 5

Impacto académico, ética de datos y desafíos institucionales

Impacto académico de Learning Analytics

El impacto académico de Learning Analytics debe entenderse con cautela. Aunque las analíticas prometen mejorar rendimiento, permanencia, retroalimentación y toma de decisiones, su efecto no depende únicamente de la disponibilidad de datos o de la precisión de los modelos. En Educación Superior virtual, el impacto aparece cuando la información se convierte en intervención pedagógica, acompañamiento oportuno, rediseño de cursos y mejora de los servicios institucionales. Una universidad puede producir muchos reportes y, aun así, no transformar las trayectorias estudiantiles si no cuenta con protocolos, equipos y decisiones académicas derivadas de esas evidencias.

Las intervenciones incorporadas en sistemas de gestión del aprendizaje muestran que Learning Analytics puede apoyar prácticas de enseñanza y aprendizaje cuando se integra en el LMS mediante alertas, tableros, retroalimentación, recomendaciones o apoyos docentes. Una revisión sistemática sobre intervenciones analíticas en LMS encontró evidencias relevantes sobre diseños, aplicaciones e impactos, pero también mostró que los resultados dependen del tipo de intervención, del contexto y de la manera en que se implementan [31]. Esta lectura evita asumir que la analítica produce mejora por sí misma.

El impacto sobre el rendimiento académico suele ser el indicador más visible, pero no siempre el más suficiente. Las calificaciones pueden mejorar por una intervención, por cambios en la evaluación, por diferencias entre cohortes o por variaciones externas al curso. En educación virtual, además, el rendimiento debe leerse junto con participación, autorregulación, satisfacción, permanencia, sentido de pertenencia y desarrollo de competencias. Si la institución solo observa aprobación, puede pasar por alto procesos de aprendizaje frágiles, experiencias de sobrecarga o desigualdades persistentes.

Learning Analytics también puede incidir en la permanencia. Las alertas tempranas, el seguimiento de participación y la tutoría focalizada permiten identificar estudiantes que requieren apoyo antes de que el abandono se consolide. Sin embargo, la permanencia no se resuelve con una notificación automática. Requiere acompañamiento académico, orientación administrativa, soporte tecnológico y condiciones institucionales que permitan responder a estudiantes con trayectorias

diversas. En este punto, el impacto depende de la capacidad de articular datos con servicios reales.

La retroalimentación es otro espacio de impacto. Las analíticas pueden mostrar al estudiante su avance, alertarlo sobre retrasos, sugerir recursos o facilitar que el docente observe errores recurrentes. Cuando la información llega a tiempo y se expresa de manera comprensible, puede fortalecer la autorregulación. Cuando se presenta como ranking, vigilancia o comparación descontextualizada, puede generar ansiedad o desmotivación. La forma en que se comunica la evidencia es parte del impacto, no un detalle secundario.

La literatura crítica sobre Learning Analytics en Educación Superior advierte que existe una distancia entre el potencial declarado y la evidencia real de mejora del aprendizaje. Un estudio bibliométrico y de contenido sobre el campo señaló que muchas investigaciones se concentran en la dimensión analítica y tecnológica, mientras el aprendizaje aparece con menor profundidad pedagógica [40]. Esta advertencia resulta importante para el libro: el impacto académico no debe medirse por la sofisticación técnica de los modelos, sino por la mejora verificable de la experiencia formativa.

El impacto, por tanto, debe ser evaluado como una cadena. Primero se producen datos; luego se construyen indicadores; después alguien interpreta; más tarde se decide una intervención; finalmente se observa si esa intervención produjo algún cambio. Si uno de esos eslabones falla, la analítica pierde fuerza educativa. En síntesis, Learning Analytics puede contribuir al rendimiento, la permanencia y la autorregulación, pero solo cuando opera dentro de una estrategia pedagógica e institucional que transforma información en apoyo concreto.

Evaluación de intervenciones basadas en analíticas

Evaluar intervenciones basadas en analíticas exige distinguir entre correlación, predicción e impacto. Una institución puede observar que ciertos estudiantes con alta actividad obtienen mejores calificaciones, pero esa relación no demuestra que aumentar accesos produzca aprendizaje. También puede identificar estudiantes en riesgo con alta precisión, pero esa precisión no prueba que la intervención posterior haya mejorado su trayectoria. En Learning Analytics, la evaluación debe preguntar no solo qué ocurrió, sino qué cambió por efecto de una acción institucional o pedagógica.



Figura 15. Evaluación de intervenciones basadas en Learning Analytics

Los diseños de evaluación pueden adoptar distintas formas. Una comparación antes-después permite observar cambios luego de implementar un tablero, alerta o recurso personalizado, pero puede confundirse con efectos de calendario, diferencias entre cohortes o cambios en la evaluación. Los estudios cuasiexperimentales comparan grupos con y sin intervención, aunque deben controlar diferencias previas. Los ensayos aleatorizados ofrecen mayor fuerza causal, pero no siempre son viables ni éticamente simples en contextos educativos. La elección del diseño debe responder al problema, al riesgo de la intervención y a las condiciones reales del curso.

La discusión sobre inferencia causal es clave porque Learning Analytics trabaja con abundantes datos observacionales. Weidlich, Gašević y Drachsler advierten que las afirmaciones causales requieren conocimiento sobre el proceso que generó los datos y proponen el uso de grafos acíclicos dirigidos para razonar sobre sesgos, confusión, sobrecontrol y variables colisionadoras [32]. Esta perspectiva ayuda a evitar conclusiones apresuradas, como atribuir una mejora de notas a una alerta cuando en realidad intervienen motivación previa, apoyo docente, experiencia digital o condiciones socioeconómicas.

Los indicadores de impacto deben definirse antes de aplicar la intervención. Pueden incluir aprobación, permanencia, logro de competencias, participación, uso de recursos, puntualidad en entregas, satisfacción, percepción de apoyo, calidad de la retroalimentación o reducción de brechas. Cada indicador mide una dimensión distinta. Si se evalúa una tutoría académica, la permanencia puede ser relevante; si se

evalúa retroalimentación personalizada, quizá importe más la calidad de revisiones posteriores; si se evalúa un dashboard estudiantil, la autorregulación puede ser un resultado central.

La revisión de intervenciones analíticas en LMS muestra que el campo ha acumulado experiencias de diseño e implementación, pero también necesita mayor precisión para comprender qué tipos de intervención funcionan, para quiénes, en qué condiciones y con qué efectos [32]. Esta pregunta es especialmente importante para la Educación Superior virtual, donde los estudiantes no constituyen un grupo homogéneo. Una intervención puede beneficiar a quienes ya tienen autonomía digital y resultar insuficiente para quienes enfrentan brechas de conectividad, tiempo o capital académico.

La evaluación también debe considerar efectos no deseados. Una alerta puede aumentar la permanencia, pero generar ansiedad; un ranking puede estimular a algunos estudiantes y desmotivar a otros; una recomendación automática puede ahorrar tiempo, pero limitar la exploración. Evaluar Learning Analytics implica medir beneficios y riesgos. La pregunta no es únicamente si la intervención funcionó, sino si funcionó de manera justa, comprensible y pedagógicamente pertinente.

Una cultura evaluativa madura documenta cada intervención: problema detectado, evidencia inicial, acción aplicada, población alcanzada, criterios de éxito, resultados, límites y ajustes futuros. Esta documentación permite aprender institucionalmente y evita que las analíticas dependan de iniciativas aisladas. Evaluar intervenciones no es un trámite posterior; es la condición para saber si los datos realmente están mejorando el aprendizaje.

Ética de datos en Learning Analytics

La ética de datos en Learning Analytics parte de una idea básica: los registros educativos no son simples rastros técnicos, sino información vinculada con personas, trayectorias, oportunidades y decisiones institucionales. En entornos virtuales de Educación Superior, los datos pueden revelar actividad académica, rendimiento, hábitos de estudio, dificultades, participación comunicativa y necesidades de apoyo. Usarlos con fines pedagógicos exige legitimidad, proporcionalidad, transparencia y protección de la dignidad estudiantil.

El consentimiento informado es una condición relevante, aunque no siempre suficiente. El estudiante debe saber qué datos se recogen, para qué se usan, quién puede acceder a ellos, durante cuánto tiempo se conservan, qué decisiones pueden

derivarse y qué opciones tiene para preguntar o reclamar. Un consentimiento formulado en lenguaje técnico, escondido en términos de uso o presentado como aceptación obligatoria pierde valor ético. La transparencia debe ser comprensible, no meramente legal.

El desarrollo de códigos de práctica ha sido una respuesta institucional a los riesgos éticos y legales de Learning Analytics. Sclater propuso un modelo para elaborar códigos que incluye revisión de literatura, estructuras de gobernanza, taxonomía de problemas, consulta con actores, publicación, difusión e incorporación institucional [33]. Esta propuesta resulta útil porque muestra que la ética no puede resolverse con una declaración general; requiere procedimientos, responsabilidades y mecanismos estables.

La minimización de datos es un principio central. No todo dato disponible debe ser recolectado, procesado o cruzado. Si el objetivo es apoyar la permanencia, quizá no sea necesario analizar mensajes personales o datos sensibles que exceden la finalidad educativa. La proporcionalidad obliga a preguntarse si el beneficio esperado justifica el tipo de dato usado, el nivel de intrusión y el riesgo de interpretación. En educación virtual, donde gran parte de la actividad queda registrada, este principio evita que la analítica derive en vigilancia generalizada.

La transparencia algorítmica también es parte de la ética. Los estudiantes y docentes no necesitan conocer todos los detalles matemáticos de un modelo, pero sí comprender qué tipo de información utiliza, qué significa una alerta, cuáles son sus límites y cómo se puede discutir una clasificación. Investigaciones recientes sobre declaraciones de uso de datos muestran que ofrecer información a estudiantes universitarios puede aumentar su conciencia sobre las prácticas de recolección y uso de datos [34]. La transparencia, por tanto, no es un adorno institucional; puede fortalecer confianza y participación.

La protección de datos personales requiere medidas técnicas y organizativas. Control de accesos, seguridad, anonimización cuando sea posible, registros de uso, políticas de retención y capacitación del personal son condiciones mínimas. Pero la protección no se agota en la seguridad informática. También importa evitar usos secundarios no autorizados, decisiones punitivas basadas en datos incompletos y comunicaciones que expongan públicamente el desempeño o riesgo de un estudiante.

Una ética de datos robusta reconoce que Learning Analytics puede beneficiar al estudiante, pero también puede dañarlo si se usa sin cuidado. La institución debe garantizar que los datos se orienten al acompañamiento, no a la sospecha; a la

mejora, no al control desproporcionado; a la equidad, no a la reproducción de desigualdades. En este libro, la ética no aparece como límite externo a la innovación, sino como condición para que la personalización sea legítima.

Sesgos, equidad y justicia algorítmica

Los sesgos en Learning Analytics pueden surgir en los datos, en los modelos, en las decisiones institucionales y en la interpretación pedagógica. Un conjunto de datos refleja prácticas previas: quién tuvo acceso a tecnología, quién recibió apoyo, quién pudo conectarse, qué actividades registró la plataforma y qué trayectorias fueron consideradas exitosas. Si esos datos se usan sin crítica, los modelos pueden reproducir desigualdades históricas bajo apariencia de neutralidad técnica.

Tabla 14. Sesgos algorítmicos y estrategias de mitigación.

Tipo de sesgo	Cómo aparece	Efecto y mitigación
Sesgo de datos históricos	Surge cuando el modelo aprende de registros anteriores que ya contienen desigualdades, como por antecedentes institucionales. Se mitiga revisando la calidad histórica de los ciertos grupos o carreras.	Puede repetir patrones injustos y ya clasificar como “en riesgo” a estudiantes. Se mitiga validando los resultados con criterio docente.
Sesgo socioeconómico/digital	Aparece cuando la baja conexión, pocos accesos o menor participación se interpretan sin incorporar información contextual y considerar conectividad, trabajo, evitando decisiones basadas solo en dispositivos o condiciones familiares.	Puede confundir dificultades de acceso con falta de compromiso. Se mitiga considerando actividad digital.
Sesgo de medición	Ocurre cuando los indicadores no representan bien el aprendizaje, si fuera aprendizaje real. Se mitiga por ejemplo, usar solo clics, combinando indicadores cuantitativos tiempo en plataforma o número de mensajes.	Puede valorar actividad superficial como aprendizaje real. Se mitiga con evidencias académicas, evaluaciones y juicio pedagógico.
Sesgo de interpretación	Se produce cuando docentes, tutores o autoridades leen los datos sin contexto o asumen que una alerta explica completamente la situación del estudiante.	Puede generar intervenciones inadecuadas o etiquetas negativas. Se mitiga contrastando los datos con una comunicación directa, tutoría y análisis del caso.
Sesgo automatizado	Aparece cuando se aceptan resultados del sistema como verdades definitivas, sin revisar cómo fueron generados ni variables influyeron.	Puede delegar decisiones educativas a algoritmos opacos. Se mitiga exigiendo supervisión humana, explicabilidad y revisión periódica y posibilidad de corregir las recomendaciones.

La equidad no consiste en tratar todos los casos de manera idéntica, sino en reconocer condiciones diferenciadas que afectan el aprendizaje. En Educación Superior virtual, las brechas de conectividad, tiempo disponible, capital académico,

alfabetización digital y responsabilidades laborales o familiares inciden en la actividad visible. Un estudiante con baja participación puede estar desmotivado, pero también puede estudiar desde un dispositivo compartido o conectarse en horarios irregulares. Si el modelo solo observa actividad en plataforma, puede confundir desigualdad de condiciones con falta de compromiso.

Khalil, Prinsloo y Slade sostienen que Learning Analytics puede apoyar a estudiantes y docentes, pero también puede exacerbar desigualdades si las reglas y supuestos de los sistemas no son examinados críticamente [38]. Esta advertencia permite ubicar la justicia algorítmica como una responsabilidad educativa. No basta con que un modelo sea preciso; debe analizarse a quién beneficia, a quién perjudica, qué oportunidades distribuye y qué consecuencias produce.

El etiquetamiento de estudiantes es uno de los riesgos más visibles. Una clasificación como “en riesgo” puede facilitar apoyo temprano, pero también puede fijar expectativas bajas, generar trato diferenciado injusto o afectar la autopercepción académica. El problema no está solo en la etiqueta, sino en el uso que se le da. Si activa tutoría respetuosa, puede ser útil; si se convierte en señal de vigilancia o exclusión, contradice el propósito pedagógico de Learning Analytics.

Los sesgos también afectan la evaluación de intervenciones. Una mejora observada puede deberse a que la intervención favoreció a estudiantes con mejores condiciones iniciales, mientras otros quedaron fuera del beneficio. La inferencia causal ayuda a identificar variables de confusión y a evitar interpretaciones simplistas [32]. En clave de justicia, evaluar una intervención requiere preguntar si redujo brechas o si solo mejoró promedios generales ocultando desigualdades internas.

La supervisión humana es necesaria, pero no suficiente si reproduce los mismos sesgos. Docentes, tutores y directivos necesitan formación para leer datos con sensibilidad ética y contextual. Revisar sesgos implica analizar variables incluidas, variables omitidas, calidad de datos, criterios de riesgo, efectos diferenciales y mecanismos de apelación. La justicia algorítmica no se logra agregando una revisión manual al final, sino incorporando equidad desde el diseño, implementación y evaluación.

La personalización justa no limita oportunidades según predicciones. Al contrario, debe ampliar apoyos, abrir rutas alternativas y evitar que los modelos reduzcan el horizonte del estudiante. Learning Analytics será equitativo si ayuda a identificar barreras para removerlas, no si convierte esas barreras en pronóstico de bajo desempeño.

Gobernanza institucional de Learning Analytics

La gobernanza institucional de Learning Analytics define cómo se toman decisiones sobre datos, modelos, responsabilidades, acceso, seguridad, ética, evaluación e impacto. Sin gobernanza, las analíticas quedan dispersas en iniciativas de cursos, áreas tecnológicas o proyectos aislados. Con gobernanza, la institución establece reglas para que los datos educativos se usen con propósito académico, protección de derechos y sostenibilidad operativa.

Tabla 15. Gobernanza institucional de Learning Analytics.

Área de gobernanza	Responsabilidad institucional	Resultado esperado
Política de datos	Definir qué datos se recogen, con qué finalidad y bajo qué normas.	Uso académico claro y legítimo de los datos educativos.
Roles institucionales	Establecer quién custodia, analiza, interpreta y actúa sobre los datos.	Evitar datos sin responsables o alertas sin intervención.
Acceso a la información	Determinar qué actores pueden consultar los datos y con qué nivel de permiso.	Protección de la privacidad y control del uso de información sensible.
Seguridad y protección	Aplicar controles técnicos, trazabilidad, permisos diferenciados y criterios de retención.	Reducción de riesgos asociados al mal uso o exposición de datos.
Comité de revisión	Evaluar proyectos analíticos, riesgos éticos, sesgos, accesos y resultados.	Decisiones más transparentes, responsables y supervisadas.
Protocolos de intervención	Definir qué hacer cuando el sistema genera una alerta académica.	Convertir los datos en acciones concretas de acompañamiento.
Auditoría de modelos	Revisar cómo funcionan los modelos, qué variables usan y qué efectos producen.	Prevención de errores, sesgos o decisiones injustas.
Comunicación institucional	Informar a estudiantes y docentes qué datos se usan y para qué.	Mayor confianza y menor percepción de vigilancia.
Evaluación de impacto	Medir si las analíticas mejoran aprendizaje, permanencia y equidad.	Verificar si Learning Analytics aporta valor real a la institución.
Sostenibilidad operativa	Asegurar recursos, infraestructura, formación y continuidad del sistema.	Implementación estable, no dependiente de proyectos aislados.

Una política institucional debe responder preguntas concretas: qué datos se recogen, quién los custodia, quién puede consultarlos, para qué finalidades se procesan, qué sistemas se integran, cómo se auditan los modelos, qué protocolos de intervención existen y cómo se informa a estudiantes y docentes. Elouazizi identifica factores críticos de gobernanza relacionados con propiedad, interpretación y toma de decisiones basada en datos dentro de Learning Analytics [22]. Estos elementos muestran que la gobernanza no es solo administración de bases de datos, sino organización del poder institucional sobre la información.

Los roles son decisivos. El área tecnológica puede garantizar infraestructura, interoperabilidad y seguridad; las unidades académicas deben definir pertinencia pedagógica; los docentes interpretan evidencias en contexto; los tutores ejecutan acompañamientos; los comités de ética revisan riesgos; las autoridades aseguran recursos y alineación estratégica. Cuando estos roles no están claros, las analíticas pueden producir datos sin responsables o alertas sin intervención.

La gobernanza también requiere comités o instancias de revisión. Estos espacios deben evaluar nuevos proyectos analíticos, revisar riesgos éticos, autorizar accesos, analizar sesgos y monitorear resultados. No se trata de burocratizar la innovación, sino de proteger la legitimidad de las decisiones. Un sistema que predice abandono, por ejemplo, debe ser revisado antes de operar, durante su uso y después de observar sus efectos.

Las políticas de Learning Analytics en Educación Superior han intentado responder a desafíos como privacidad, ética, estrategia, comunicación con actores, evaluación de impacto y alfabetización de datos. Tsai y Gašević, al revisar ocho políticas institucionales, encontraron la necesidad de fortalecer canales de comunicación, enfoques pedagógicos, formación para usuarios y mecanismos para evaluar efectividad y legitimidad [35]. Esta evidencia plantea la idea de que la gobernanza debe ser pedagógica y participativa, no solo normativa.

La seguridad de la información es otra dimensión central. Los datos educativos deben protegerse mediante controles técnicos, permisos diferenciados, trazabilidad y criterios de retención. Pero una institución puede tener seguridad técnica y aun así carecer de gobernanza si no sabe justificar el uso de los datos o si permite decisiones automatizadas sin revisión. La seguridad protege archivos; la gobernanza protege procesos, derechos y finalidades.

Una gobernanza madura hace sostenible Learning Analytics porque evita improvisaciones, duplicidades y usos contradictorios. Permite escalar sin perder control, innovar sin vulnerar derechos y evaluar sin reducir la complejidad educativa. En Educación Superior virtual, gobernar los datos es gobernar una parte importante de la experiencia académica.

Cultura institucional basada en evidencia

Una cultura institucional basada en evidencia no se crea por instalar tableros ni por exigir reportes periódicos. Se construye cuando la comunidad universitaria aprende a formular preguntas, interpretar datos, contrastar hipótesis, discutir hallazgos y tomar decisiones revisables. En Learning Analytics, la evidencia debe servir para mejorar el aprendizaje y la enseñanza, no para multiplicar métricas sin uso claro.

Tabla 16. Cultura institucional basada en evidencia.

Práctica institucional	Cómo se aplica en Learning Analytics	Propósito
Formular preguntas académicas	Definir qué problema se quiere comprender: bajo rendimiento, abandono, poca participación o necesidad de apoyo.	Evitar recopilar datos sin una finalidad educativa clara.
Interpretar datos con contexto	Analizar indicadores considerando condiciones del estudiante, diseño del curso y mediación docente.	No convertir una métrica en una conclusión automática.
Alfabetización en datos	Capacitar a docentes, tutores, gestores y estudiantes sobre el significado y límites de los indicadores.	Mejorar la lectura crítica de dashboards, alertas y reportes.
Discusión colectiva de evidencias	Revisar los hallazgos entre docentes, tutores, coordinadores y equipos técnicos.	Tomar decisiones compartidas y no aisladas.
Comunicación transparente	Informar qué datos se recogen, para qué se usan y quién puede acceder a ellos.	Generar confianza y evitar percepción de vigilancia.
Uso pedagógico de dashboards	Seleccionar pocos indicadores relevantes y accionables.	Evitar saturación de información y decisiones superficiales.
Decisiones revisables	Evaluar si las acciones tomadas a partir de los datos realmente mejoran el aprendizaje.	Promover mejora continua y corrección de errores.
Participación estudiantil	Devolver la evidencia al estudiante mediante retroalimentación, orientación o recomendaciones.	Fortalecer la autorregulación y la toma de decisiones sobre su aprendizaje.
Confianza institucional	Explicar beneficios, límites y responsabilidades del uso de Learning Analytics.	Reducir resistencias y fortalecer la legitimidad del sistema.
Mejora continua	Usar la evidencia para ajustar cursos, tutorías, recursos y políticas académicas.	Convertir los datos en acciones educativas sostenibles.

La toma de decisiones basada en datos exige alfabetización institucional. Docentes, tutores, gestores y estudiantes necesitan comprender qué representan los indicadores, qué límites tienen y qué acciones pueden derivarse de ellos. Si un dashboard muestra baja participación, el usuario debe saber que esa señal requiere interpretación contextual. Si una alerta predice riesgo, debe entender que no es una

sentencia. La formación en datos es tan importante como la infraestructura tecnológica.

Las políticas revisadas por Tsai y Gašević muestran que muchas instituciones necesitan fortalecer la comunicación entre actores, los enfoques pedagógicos y la orientación para desarrollar alfabetización de datos en usuarios finales [35]. Esta necesidad es especialmente visible en programas virtuales, donde los datos circulan entre plataformas, áreas administrativas y equipos docentes. Sin lenguaje común, cada actor interpreta las métricas de manera distinta y la evidencia pierde capacidad de orientar acciones.

La resistencia al cambio no debe leerse como simple oposición a la tecnología. Puede expresar desconfianza ante el uso de datos, experiencias previas de control, falta de tiempo, desconocimiento de los modelos o temor a que los indicadores se usen para evaluar desempeño docente de manera reduccionista. Una cultura de evidencia requiere confianza. Para construirla, la institución debe explicar fines, límites, responsabilidades y beneficios de Learning Analytics.

La transparencia con los estudiantes también forma parte de esta cultura. Cuando los estudiantes reciben información clara sobre la recolección y uso de sus datos, aumenta su posibilidad de participar de manera informada [34]. La evidencia no debe circular solo hacia arriba, como insumo para gestión; también debe volver al estudiante en forma de retroalimentación, orientación y capacidad de decisión sobre su aprendizaje.

El uso estratégico de dashboards debe evitar la saturación. Demasiados indicadores pueden producir sobrecarga y decisiones superficiales. Una cultura madura selecciona pocas métricas significativas, las interpreta con criterios pedagógicos y las revisa periódicamente. La pregunta institucional no es cuántos datos puede visualizar, sino qué decisiones mejoran cuando esos datos se leen bien.

Integrar áreas académicas, tecnológicas y administrativas es una condición de sostenibilidad. La evidencia sobre permanencia puede requerir datos de plataforma, matrícula, tutoría, bienestar estudiantil y evaluación. Si cada área conserva información aislada, la institución solo ve fragmentos de la trayectoria. Una cultura basada en evidencia articula esos fragmentos sin perder de vista que el estudiante no es un conjunto de variables, sino una persona en formación.

Desafíos técnicos, pedagógicos y organizacionales

La implementación de Learning Analytics enfrenta desafíos técnicos, pedagógicos y organizacionales que suelen aparecer de manera simultánea. Una institución puede contar con plataformas y datos, pero carecer de interoperabilidad; puede tener modelos predictivos, pero no protocolos de intervención; puede disponer de tableros, pero no de docentes formados para interpretarlos. Estos desajustes explican por qué muchas iniciativas prometedoras no logran escalar ni sostener impacto.

La fragmentación de datos es un problema frecuente. Los registros del LMS, sistemas académicos, bibliotecas digitales, tutorías, bienestar estudiantil y plataformas externas suelen estar dispersos, con formatos distintos y niveles variables de calidad. Integrarlos requiere arquitectura tecnológica, estándares, limpieza de datos y acuerdos institucionales. Sin esa base, los modelos pueden trabajar con información incompleta y generar interpretaciones débiles.

Tabla 17. Desafíos para implementar Learning Analytics.

Tipo de desafío	Problema e impacto	Acción
Técnico	Los sistemas no se integran correctamente, los datos están incompletos o los dashboards presentan información poco confiable. Esto limita el seguimiento académico y puede generar decisiones basadas en datos erróneos.	Integrar plataformas, validar y mantener infraestructura estable.
Pedagógico	Los indicadores se usan sin interpretación educativa o se reducen a métricas de actividad, como clics o conexiones. Esto puede confundir participación con aprendizaje real.	Definir indicadores con sentido pedagógico y capacitar a docentes en interpretación de datos.
Ético	Se pueden usar datos sensibles sin claridad sobre finalidad, consentimiento o privacidad. Esto puede generar vigilancia, etiquetamiento o pérdida de confianza estudiantil.	Establecer protocolos de uso ético, consentimiento, privacidad y supervisión humana.
Organizacional	No existen roles claros para actuar frente a alertas, riesgos o reportes analíticos. Esto provoca respuestas tardías o duplicación de esfuerzos.	Definir responsabilidades, flujos de intervención y protocolos institucionales.
Cultural	Docentes, estudiantes o autoridades pueden desconfiar de la analítica o verla como control. Esto dificulta su adopción y uso formativo.	Promover una cultura de evidencia, no de sanción.
Normativo	La institución puede carecer de políticas claras sobre acceso, almacenamiento, uso y eliminación de datos educativos. Esto aumenta riesgos legales y administrativos.	Crear normativa interna de gobernanza de datos, seguridad y trazabilidad.
Financiero	La implementación requiere inversión en plataformas, capacitación, soporte técnico y mantenimiento. Si no hay presupuesto sostenible, el proyecto puede quedar incompleto.	Planificar inversión gradual, priorizar necesidades críticas y evaluar costo-beneficio.

La interoperabilidad limitada afecta la capacidad de seguimiento. Si un estudiante participa en videoconferencias, consulta recursos externos y recibe tutoría por otro sistema, parte de su experiencia queda fuera del análisis. Esto no significa que todo deba registrarse, pero sí que la institución debe definir qué datos son necesarios y cómo se integran de manera proporcional. La gobernanza de datos ayuda a establecer esos criterios [22].

Los desafíos pedagógicos son igual de importantes. Una analítica puede detectar bajo acceso, pero no explicar comprensión; puede señalar un patrón de retraso, pero no identificar por sí misma la causa. La interpretación incorrecta de indicadores puede conducir a intervenciones inadecuadas. Si se confunde actividad con aprendizaje, velocidad con compromiso o predicción con diagnóstico, Learning Analytics pierde valor educativo y puede generar decisiones injustas.

Las políticas institucionales revisadas en Educación Superior muestran que los desafíos de adopción incluyen estrategia, comunicación entre actores, orientación pedagógica, evaluación de impacto y desarrollo de capacidades [35]. Esto confirma que Learning Analytics no se implementa como una herramienta aislada, sino como un proceso institucional. Requiere liderazgo, recursos, formación, soporte técnico, evaluación y participación de la comunidad universitaria.

La sostenibilidad financiera y operativa también debe considerarse. Desarrollar modelos, mantener infraestructura, auditar sesgos, capacitar equipos y responder a alertas tiene costos. Una institución puede iniciar un proyecto piloto con entusiasmo y abandonarlo cuando se agotan recursos o cuando el volumen de alertas supera la capacidad tutorial. Escalar Learning Analytics exige prever carga de trabajo, mantenimiento y mejora continua.

La literatura crítica advierte que el campo ha producido mucha analítica, pero no siempre suficiente comprensión del aprendizaje [36]. Este desafío invita a no sobredimensionar la técnica. El futuro de Learning Analytics en la universidad dependerá menos de acumular datos y más de articularlos con teorías de aprendizaje, diseño instruccional, ética, equidad y capacidad institucional para actuar. La dificultad no está solo en calcular mejor, sino en educar mejor con evidencia.

Perspectivas futuras de Learning Analytics

Las perspectivas futuras de Learning Analytics en Educación Superior virtual estarán marcadas por la inteligencia artificial responsable, la analítica multimodal, los

modelos explicables, la personalización contextual y la integración con trayectorias de aprendizaje a lo largo de la vida. Sin embargo, el futuro del campo no debe imaginarse como una expansión ilimitada de datos, sino como una mejora de la capacidad universitaria para comprender y acompañar procesos formativos complejos.

La inteligencia artificial aumentará la capacidad de procesar información, detectar patrones y generar recomendaciones. También incrementará la necesidad de transparencia, auditoría y supervisión humana. Los modelos futuros deberán explicar por qué sugieren una intervención, qué datos usan, qué incertidumbre tienen y cómo pueden ser cuestionados. Una analítica poderosa pero opaca no fortalecerá la confianza institucional.



Figura 16. Tendencias futuras de Learning Analytics en Educación Superior.

La analítica multimodal abre posibilidades para integrar datos de texto, audio, video, interacción, producción escrita, colaboración y desempeño. En cursos virtuales e híbridos, esto podría ofrecer una comprensión más rica del aprendizaje. No obstante, también amplía riesgos de vigilancia y tratamiento excesivo de información sensible. El principio de proporcionalidad será más importante: no todo dato técnicamente capturable debe convertirse en dato educativo.

La personalización hipercontextual puede adaptar recursos, apoyos y retroalimentación según trayectorias, metas, necesidades y condiciones del

estudiante. Para que sea legítima, debe evitar encerrar a las personas en perfiles rígidos. Las discusiones sobre equidad, responsabilidad y transparencia muestran que no existen respuestas simples para garantizar una Learning Analytics justa; se requiere investigación, diseño responsable y revisión continua [38]. En el futuro, la calidad de la personalización se medirá también por su capacidad de no discriminar.

Las microcredenciales y el aprendizaje a lo largo de la vida pueden ampliar el alcance de Learning Analytics más allá de una asignatura o programa. Las universidades podrían acompañar trayectorias flexibles, reconocer logros parciales y orientar rutas profesionales. Pero esto exige gobernanza sobre portabilidad de datos, consentimiento, interoperabilidad y límites de uso. Una trayectoria académica extendida no debe convertirse en expediente permanente de vigilancia.

La crítica sobre el predominio de la analítica frente al aprendizaje seguirá siendo necesaria. Guzmán-Valenzuela y colegas advierten que parte de la producción del campo se ha concentrado más en tecnologías, datos y métodos que en una comprensión profunda de los procesos de enseñanza y aprendizaje [40]. Esta advertencia debe orientar las líneas futuras: más investigación situada, más evaluación longitudinal, más participación docente y estudiantil, y mayor atención a contextos latinoamericanos.

Las universidades inteligentes del futuro no serán las que automaticen más decisiones, sino las que aprendan mejor de sus propias evidencias. Learning Analytics tendrá valor si ayuda a reducir brechas, fortalecer permanencia, mejorar retroalimentación, diseñar cursos más pertinentes y sostener decisiones éticas. Su horizonte no es reemplazar la pedagogía, sino darle mejores condiciones para actuar con oportunidad, justicia y sentido académico.

Conclusiones

Learning Analytics se ha consolidado como una técnica fundamental para fortalecer la Educación Superior virtual, siempre que la interpretación de los datos educativos responda a objetivos pedagógicos y no se limite a simples registros técnicos. Los datos producidos en plataformas digitales pueden facilitar la identificación de necesidades estudiantiles, el seguimiento académico, la personalización de recursos y la toma de decisiones institucionales; sin embargo, su eficacia depende de la calidad de los indicadores, la contextualización de los datos y la participación responsable de docentes, tutores y administradores. En consecuencia, Learning Analytics no debe percibirse como un sustituto del acompañamiento humano, sino como un instrumento para mejorar la comprensión de las trayectorias de aprendizaje de los estudiantes y atender con mayor rapidez las dificultades académicas.

De igual manera, el libro sostiene que la implementación de Learning Analytics requiere una profunda transformación digital sustentada en gobernanza, ética de datos, transparencia y justicia algorítmica. Contar con plataformas, modelos predictivos o sistemas de recomendación no es suficiente; resulta imprescindible garantizar que su aplicación promueva la equidad, la permanencia estudiantil y la calidad educativa, evitando prácticas de vigilancia, etiquetamiento o toma de decisiones automatizadas sin supervisión. En este sentido, Learning Analytics alcanza su verdadero potencial únicamente cuando se incorpora a una cultura institucional basada en evidencia, orientada a la mejora continua y centrada en el estudiante.

El libro plantea que Learning Analytics ofrece una posibilidad significativa para desarrollar un modelo de Educación Superior virtual más personalizado, ético y pertinente. Su principal aporte no reside en la tecnología en sí misma, sino en la capacidad de las instituciones para convertir los datos en acciones pedagógicas equitativas, oportunas y evaluables, priorizando de manera constante el desarrollo humano dentro del marco educativo.

Contribución y autoría

V.S.V.T., V.S.E.A., V.S.J. A., y F.S.L.: conceptualización, análisis formal, investigación, metodología, financiamiento, redacción del borrador original, y revisión y edición del manuscrito final.

Financiamiento

Este trabajo fue financiado por la Universidad Estatal de Bolívar en el marco de sus actividades de investigación.

Declaración ética

Este estudio no involucró experimentación directa ni intervención clínica con seres humanos ni con animales por parte del autor, por lo que no se requirió la aprobación específica de un comité de ética institucional para su ejecución.

Uso de inteligencia artificial

La concepción del estudio, análisis e interpretación de los resultados, así como la redacción y revisión del manuscrito, fueron realizados de manera autónoma por los autores, quienes asumen la responsabilidad plena por el contenido de la obra.

Disponibilidad de datos

Los datos utilizados en esta investigación están disponibles a través de los autores de correspondencia, previa solicitud razonable.

Conflicto de interés

Los autores declaran no tener ningún conflicto de interés de carácter financiero, académico o personal en relación con la realización, interpretación o publicación del presente trabajo de investigación.

Referencias

- [1] L. M. Castro Benavides, J. A. Tamayo Arias, y D. Burgos, «Características distintivas de la transformación digital en las instituciones de educación superior. Revisión sistemática de literatura», presentado en Nuevas realidades para la educación en ingeniería: currículo, tecnología, medio ambiente y desarrollo, sep. 2022, pp. 1-11. doi: 10.26507/paper.2127.
- [2] E. Sánchez Díaz y O. M. Dávila Rojas, «El aprendizaje virtual en la educación superior: Una revisión sistemática», *revistahorizontes*, vol. 8, n.º 34, pp. 1866-1883, jul. 2024, doi: 10.33996/revistahorizontes.v8i34.839.
- [3] A. C. Urquidi Martin, M. S. Calabor Prieto, y C. Tamarit Aznar, «Entornos virtuales de aprendizaje: modelo ampliado de aceptación de la tecnología», *REDIE*, vol. 21, pp. 1-12, jun. 2019, doi: 10.24320/redie.2019.21.e22.1866.
- [4] S. Martínez De Miguel López, A. Bernárdez-Gómez, y J. A. Salmeron Aroca, «Análisis retrospectivo de la percepción sobre herramientas para el desarrollo de actividades colaborativas en entornos virtuales», *RIED*, vol. 27, n.º 2, abr. 2024, doi: 10.5944/ried.27.2.38983.
- [5] B. De Benito, J. Moreno García, y S. Villatoro Moral, «Entornos tecnológicos en el codiseño de itinerarios personalizados de aprendizaje en la enseñanza superior», *EduTec-e*, n.º 74, pp. 73-93, dic. 2020, doi: 10.21556/edutec.2020.74.1843.
- [6] C. Coll Salvador, F. Díaz Barriga Arceo, A. Engel Rocamora, y J. Salinas Ibáñez, «Evidencias de aprendizaje en prácticas educativas mediadas por tecnologías digitales», *RIED*, vol. 26, n.º 2, pp. 9-25, abr. 2023, doi: 10.5944/ried.26.2.37293.
- [7] L. García Aretio, «El problema del abandono en estudios a distancia. Respuestas desde el Diálogo Didáctico Mediado», *RIED*, vol. 22, n.º 1, p. 245, ene. 2019, doi: 10.5944/ried.22.1.22433.
- [8] P. Kohls Dos Santos y L. M. Martins Giraffa, «Permanência na Educação Superior a distância», *RIED*, vol. 20, n.º 1, p. 305, ene. 2017, doi: 10.5944/ried.20.1.16808.
- [9] K. Lobos, J. Mella-Norambuena, C. Bruna, y C. Fernández, «Analíticas de aprendizaje para la toma de decisiones pedagógicas en educación superior», *Form. Univ.*, vol. 15, n.º 4, pp. 33-48, ago. 2022, doi: 10.4067/S0718-50062022000400033.

- [10] D. Domínguez Figaredo, «Data-driven educational algorithms pedagogical framing», *RIED*, vol. 23, n.º 2, p. 65, jul. 2020, doi: 10.5944/ried.23.2.26470.
- [11] J. A. Salazar Cardona y J. I. Triviño Arbelaez, «Aplicación de Learning Analytics y Educational Data Mining en una institución de educación superior en Colombia», *rev.ing.univ.Medellin*, vol. 19, n.º 36, pp. 71-89, jun. 2019, doi: 10.22395/rium.v19n36a4.
- [12] J. A. Ruipérez-Valiente, «El Proceso de Implementación de Analíticas de Aprendizaje», *RIED*, vol. 23, n.º 2, p. 85, jul. 2020, doi: 10.5944/ried.23.2.26283.
- [13] R. Hidalgo y G. Evans, «Analytics for Action: Assessing effectiveness and impact of data informed interventions on online modules», *RIED*, vol. 23, n.º 2, p. 103, jul. 2020, doi: 10.5944/ried.23.2.26450.
- [14] M. V. Dias Júnior y L. P. Mercado, «Ações docentes nos Ambientes Virtuais de Aprendizagem proporcionadas pelas ferramentas de Learning Analytics», *RIEOEI*, vol. 80, n.º 1, pp. 117-137, may 2019, doi: 10.35362/rie8013459.
- [15] I. A. Cedillo Martínez y L. F. García Jiménez, «Modelado de un sistema de reinscripciones escalable sobre una nube híbrida usando Learning Analytics», *TIES*, n.º 14, pp. 33-46, dic. 2025, doi: 10.22201/dgtic.26832968e.2025.14.99.
- [16] P. Chejara et al., «The Impact of Attribute Noise on the Automated Estimation of Collaboration Quality Using Multimodal Learning Analytics in Authentic Classrooms», *Learning Analytics*, vol. 11, n.º 2, pp. 73-90, jun. 2024, doi: 10.18608/jla.2024.8253.
- [17] E. Acosta-Gonzaga y A. Ramirez-Arellano, «Estudio comparativo de técnicas de analítica del aprendizaje para predecir el rendimiento académico de los estudiantes de educación superior», *CienciaUAT*, pp. 63-74, ago. 2020, doi: 10.29059/cienciauat.v15i1.1392.
- [18] S. Lonn y B. Koester, «Rearchitcting Data for Researchers: A Collaborative Model for Enabling Institutional Learning Analytics in Higher Education», *Learning Analytics*, vol. 6, n.º 2, jul. 2019, doi: 10.18608/jla.2019.62.8.
- [19] R. Ferguson y D. Clow, «Consistent Commitment: Patterns of Engagement across Time in Massive Open Online Courses (MOOCs)», *Learning Analytics*, vol. 2, n.º 3, pp. 55-80, feb. 2016, doi: 10.18608/jla.2015.23.5.

-
- [20] N. Bergdahl, M. Bond, J. Sjöberg, M. Dougherty, y E. Oxley, «Unpacking student engagement in higher education learning analytics: a systematic review», *Int J Educ Technol High Educ*, vol. 21, n.º 1, p. 63, dic. 2024, doi: 10.1186/s41239-024-00493-y.
- [21] A. N. Cormack, «A Data Protection Framework for Learning Analytics», *Learning Analytics*, vol. 3, n.º 1, abr. 2016, doi: 10.18608/jla.2016.31.6.
- [22] N. Elouazizi, «Critical Factors In Data Governance For Learning Analytics», *Learning Analytics*, vol. 1, n.º 3, pp. 211-222, ago. 2014, doi: 10.18608/jla.2014.13.25.
- [23] M. A. Chatti y A. Muslim, «The PERLA Framework: Blending Personalization and Learning Analytics», *IRRODL*, vol. 20, n.º 1, feb. 2019, doi: 10.19173/irrodl.v20i1.3936.
- [24] G. Ramaswami, T. Susnjak, y A. Mathrani, «Effectiveness of a Learning Analytics Dashboard for Increasing Student Engagement Levels», *Learning Analytics*, vol. 10, n.º 3, pp. 115-134, dic. 2023, doi: 10.18608/jla.2023.7935.
- [25] R. J. Waddington, S. Nam, S. Lonn, y S. D. Teasley, «Improving Early Warning Systems with Categorized Course Resource Usage», *Learning Analytics*, vol. 3, n.º 3, pp. 263-290, dic. 2016, doi: 10.18608/jla.2016.33.13.
- [26] I. Rets, C. Herodotou, y A. Gillespie, «Six Practical Recommendations Enabling Ethical Use of Predictive Learning Analytics in Distance Education», *Learning Analytics*, vol. 10, n.º 1, pp. 149-167, feb. 2023, doi: 10.18608/jla.2023.7743.
- [27] H. Khosravi, K. Kitto, y J. J. Williams, «RiPPLE: A Crowdsourced Adaptive Platform for Recommendation of Learning Activities», *Learning Analytics*, vol. 6, n.º 3, dic. 2019, doi: 10.18608/jla.2019.63.12.
- [28] D. Ifenthaler, D. Gibson, y E. Dobozy, «The synergistic and dynamic relationship between learning design and learning analytics», *APUBS*, pp. 112-116, nov. 2017, doi: 10.14742/apubs.2017.752.
- [29] F. Jin, B. Maheshi, R. Martinez-Maldonado, D. Gašević, y Y.-S. Tsai, «Scaffolding Feedback Literacy: Designing a Feedback Analytics Tool with Students», *Learning Analytics*, vol. 11, n.º 2, pp. 123-137, jul. 2024, doi: 10.18608/jla.2024.8339.
- [30] O. Zawacki-Richter, V. I. Marín, M. Bond, y F. Gouverneur, «Systematic review of research on artificial intelligence applications in higher education – where are

- the educators?», *Int J Educ Technol High Educ*, vol. 16, n.º 1, p. 39, dic. 2019, doi: 10.1186/s41239-019-0171-0.
- [31] Z. Pan, L. Biegley, A. Taylor, y H. Zheng, «A Systematic Review of Learning Analytics: Incorporated Instructional Interventions on Learning Management Systems», *Learning Analytics*, vol. 11, n.º 2, pp. 52-72, may 2024, doi: 10.18608/jla.2023.8093.
- [32] J. Weidlich, D. Gašević, y H. Drachsler, «Causal Inference and Bias in Learning Analytics: A Primer on Pitfalls Using Directed Acyclic Graphs», *Learning Analytics*, vol. 9, n.º 3, pp. 183-199, dic. 2022, doi: 10.18608/jla.2022.7577.
- [33] N. Sclater, «Developing a Code of Practice for Learning Analytics», *Learning Analytics*, vol. 3, n.º 1, abr. 2016, doi: 10.18608/jla.2016.31.3.
- [34] S. Sepp, «Towards More Transparency in Learning Analytics: Sharing Information with University Students Increases their Awareness of Data Collection Practices», *Learning Analytics*, vol. 12, n.º 3, pp. 34-46, nov. 2025, doi: 10.18608/jla.2025.8713.
- [35] Y.-S. Tsai y D. Gasevic, «Learning analytics in higher education --- challenges and policies: a review of eight learning analytics policies», en *Proceedings of the Seventh International Learning Analytics & Knowledge Conference*, Vancouver British Columbia Canada: ACM, mar. 2017, pp. 233-242. doi: 10.1145/3027385.3027400.
- [36] C. Guzmán-Valenzuela, C. Gómez-González, A. Rojas-Murphy Tagle, y A. Lorca-Vyhmeister, «Learning analytics in higher education: a preponderance of analytics but very little learning?», *Int J Educ Technol High Educ*, vol. 18, n.º 1, p. 23, dic. 2021, doi: 10.1186/s41239-021-00258-x.

Descargo de responsabilidad

Los libros y capítulos de libros publicados en la Editorial Unión Científica representan únicamente las opiniones de los autores. La Editorial Unión Científica, su equipo editorial y sus revisores no se hacen responsables del contenido, las interpretaciones o las consecuencias derivadas de la aplicación de los métodos o conclusiones incluidos en los trabajos. Todas las publicaciones se rigen por las políticas éticas de la editorial.



EDITORIAL
UNIÓN CIENTÍFICA