

Compás
capacitación e investigación

Analítica del aprendizaje e inteligencia artificial: predicción, personalización y dilemas éticos en educación

María Mercedes Tapia Galarza
María Elizabeth Espinel Ramos
Lorena Elizabeth Quiñónez Segovia
Sandra Elizabeth Salazar Bedón
Jessica Elizabeth Pacheco Espinel
Mónica Jessy Cadena Guanoluisa

Analítica del aprendizaje e inteligencia artificial: predicción, personalización y dilemas éticos en educación

María Mercedes Tapia Galarza
María Elizabeth Espinel Ramos
Lorena Elizabeth Quiñónez Segovia
Sandra Elizabeth Salazar Bedón
Jessica Elizabeth Pacheco Espinel
Mónica Jessy Cadena Guanoluisa

ISBN: 978-9942-53-237-4
Primera edición, 2026

© María Mercedes Tapia Galarza
Magíster en Pedagogía.
Unidad Educativa Vicente León.
Latacunga, Cotopaxi, Ecuador.
mariam.tapia@docentes.educacion.edu.ec
https://orcid.org/0009-0001-9314-1720

María Elizabeth Espinel Ramos
Licenciada en Pedagogía.
Unidad Educativa Vicente León.
Latacunga, Cotopaxi, Ecuador.
elizabeth.espinel@docentes.educacion.edu.ec
https://orcid.org/0009-0006-1535-0865

Lorena Elizabeth Quiñónez Segovia
Magíster en Docencia Universitaria y Administración Educativa.
Unidad Educativa Vicente León.
Latacunga, Cotopaxi, Ecuador.
lorenae.quinonez@docentes.educacion.edu.ec
https://orcid.org/0009-0008-8922-7688

Sandra Elizabeth Salazar Bedón
Magíster en Docencia Universitaria.
Unidad Educativa Vicente León.
Latacunga, Cotopaxi, Ecuador.
sandra.salazarb@docentes.educacion.edu.ec
https://orcid.org/0009-0009-7147-0863

Jessica Elizabeth Pacheco Espinel
Magíster en Gerencia y Liderazgo Educacional.
Unidad Educativa Luis Fernando Ruiz.
Latacunga, Cotopaxi, Ecuador.
jessica.pacheco@docentes.educacion.edu.ec
https://orcid.org/0009-0004-7007-5005

Mónica Jessy Cadena Guanoluisa
Maestría en Educación Bilingüe.
Unidad Educativa Vicente León.
Latacunga, Cotopaxi, Ecuador.
jessy.cadena@docentes.educacion.edu.ec
https://orcid.org/0009-0005-6247-5313

© Editorial Grupo Compás, 2026
GuayaquiL, Ecuador
www.grupocompas.com
http://repositorio.grupocompas.com

Primera edición, 2026

Esta obra ha sido sometida a un proceso de evaluación bajo el sistema de arbitraje doble ciego (double-blind peer review), garantizando el anonimato tanto de los autores como de los evaluadores externos. El dictamen favorable certifica que el contenido cumple con los más altos estándares de rigor científico, calidad editorial y originalidad exigidos por la comunidad académica internacional para su indexación y reconocimiento científico.

ISBN: 978-9942-53-237-4
DOI: 10.31876/9789942532374
Distribución online
Acceso abierto

CC BY NC SA

Cita
Tapìa, M., Espinel, M., Salazar, S., Pacheco, J., Cadena, M. (2026) Analítica del aprendizaje e inteligencia artificial: predicción, personalización y dilemas éticos en educación. Editorial Grupo Compás.

Índice

INTRODUCCIÓN 5

Capítulo 1 9

Fundamentos de la analítica del aprendizaje y la inteligencia artificial en educación 9

Del registro de información a la comprensión del aprendizaje. 9

Del dato al significado pedagógico 9

La pregunta educativa como punto de partida 12

Comprender el aprendizaje en su contexto 13

La interpretación como responsabilidad compartida 14

Analítica del aprendizaje, minería de datos educativos e inteligencia artificial: diferencias y relaciones. 15

Tipos de analítica: descriptiva, diagnóstica, predictiva y prescriptiva. 17

Datos, indicadores y modelos: cómo se construye una representación del estudiante. 20

Fundamentos pedagógicos: evaluación formativa, autorregulación y aprendizaje situado. 23

Calidad de los datos y validez de las interpretaciones: límites de lo que puede medirse. 26

Capítulo 2 30

Nuevas competencias para el ejercicio profesional docente 30

Propósitos de la predicción: desempeño, dificultades académicas y abandono. 30

Construcción de modelos predictivos: variables, entrenamiento y validación, explicados para el lector educativo 33

Interpretación de resultados: precisión, incertidumbre y consecuencias de los errores 36

Sistemas de alerta temprana y organización del acompañamiento 40

De la predicción a la intervención: diferencias entre anticipar un resultado y modificarlo 43

Evidencia de efectividad y transferencia entre niveles e instituciones educativas 46

Capítulo 3 50

Personalización del aprendizaje y mediación docente 50

Personalización, diferenciación y adaptación: precisiones conceptuales 50

Sistemas adaptativos, tutores inteligentes y recomendación de recursos 53

Retroalimentación y paneles de analítica para docentes y estudiantes 56

Autorregulación, participación y autonomía del estudiante 62

Diseño y evaluación de experiencias personalizadas: aprendizaje, inclusión y carga de trabajo docente 64

Capítulo 4 67

Dilemas éticos y gobernanza de los datos educativos 67

Privacidad, consentimiento y protección de datos: atención particular a menores de edad 67

Sesgos algorítmicos, discriminación y desigualdad educativa 69

Vigilancia, etiquetado y efectos sobre las trayectorias estudiantiles 74

Responsabilidades institucionales y relaciones con proveedores tecnológicos 76

Condiciones de implementación en contextos latinoamericanos y ecuatorianos 78

Criterios para adoptar, evaluar, revisar o retirar un sistema 80

CONCLUSIONES 85

REFERENCIAS 86

INTRODUCCIÓN

La expansión de los entornos digitales de enseñanza ha ampliado las posibilidades de registrar y analizar información sobre los procesos educativos. Las plataformas de aprendizaje, las evaluaciones en línea y los sistemas de gestión académica generan datos sobre actividades, respuestas, interacciones y trayectorias estudiantiles. Estos registros pueden contribuir a reconocer dificultades, orientar la retroalimentación y apoyar decisiones docentes e institucionales. Sin embargo, su disponibilidad no garantiza una comprensión suficiente del aprendizaje: transformar los datos en conocimiento educativo requiere interpretarlos en relación con los objetivos formativos y las condiciones en las que se producen (Ifenthaler & Yau, 2020; Zawacki-Richter et al., 2019).

En este escenario, la analítica del aprendizaje se ocupa del análisis de datos sobre los estudiantes y sus contextos para comprender y apoyar los procesos de enseñanza y aprendizaje. Su desarrollo comprende aplicaciones diversas, desde la visualización de información hasta la identificación de patrones asociados con el desempeño o la continuidad de los estudios. La revisión de Sousa et al. (2021), centrada en educación secundaria, muestra usos relacionados con la predicción de resultados, la detección de estudiantes que requieren apoyo y la elaboración de visualizaciones para orientar la práctica educativa. Esta diversidad permite entender la analítica como un campo de intervención pedagógica e institucional, cuya relevancia depende de las preguntas que orientan el análisis y de las decisiones que se toman a partir de sus resultados.

La inteligencia artificial amplía estas posibilidades mediante sistemas capaces de identificar regularidades en los datos, estimar resultados y adaptar determinadas respuestas educativas. La analítica del aprendizaje y la inteligencia artificial mantienen, por tanto, una relación de convergencia, aunque sus ámbitos no son equivalentes: analizar información educativa puede apoyarse en procedimientos estadísticos y visualizaciones, mientras que las aplicaciones de inteligencia artificial incluyen, además, sistemas de tutoría, evaluación y adaptación de actividades. En educación superior, Zawacki-Richter et al. (2019) identificaron cuatro áreas principales de aplicación: elaboración de perfiles y predicción, evaluación, sistemas adaptativos y personalización, y tutoría inteligente. Esta clasificación ayuda a delimitar un campo que suele presentarse de manera excesivamente homogénea.

La predicción constituye uno de sus usos más relevantes y, al mismo tiempo, uno de los que exige mayor cautela. Anticipar posibles dificultades académicas

puede facilitar el acompañamiento antes de que estas se traduzcan en reprobación o abandono. No obstante, una predicción expresa una estimación condicionada por los datos y el contexto; su utilidad educativa depende de que permita organizar una respuesta pertinente. Ifenthaler y Yau (2020) encontraron aplicaciones prometedoras para apoyar el éxito académico, pero también señalaron la insuficiencia de evidencia rigurosa a gran escala en la literatura examinada. Un estudio posterior de Alalawi et al. (2025) ilustra la articulación entre modelos predictivos e intervenciones docentes mediante un marco que incorpora identificación de dificultades y planes de estudio personalizados. Sus resultados favorables aportan evidencia situada, sin resolver por sí solos la cuestión de su transferencia a otras instituciones y poblaciones.

La personalización plantea una segunda cuestión: cómo responder a las diferencias entre estudiantes sin convertirlas en categorías rígidas que restrinjan sus oportunidades. Adaptar actividades, apoyos o retroalimentación puede contribuir a atender necesidades específicas, pero exige definir qué se pretende mejorar y cómo se evaluará esa mejora. La revisión de Matcha et al. (2020), realizada desde la perspectiva del aprendizaje autorregulado, identificó limitaciones en la fundamentación teórica y en la evaluación de los paneles de analítica del aprendizaje. Sus hallazgos cuestionan la suposición de que mostrar indicadores al estudiante basta para favorecer la reflexión o modificar sus estrategias. La información necesita acompañarse de orientaciones comprensibles y oportunidades de actuación.

Estas limitaciones sitúan la mediación docente en el centro del debate. Interpretar una alerta, valorar la pertinencia de una recomendación o reconocer lo que un indicador omite requiere conocimiento pedagógico y comprensión del contexto. La revisión de revisiones de Bond et al. (2024) identificó la necesidad de fortalecer las consideraciones éticas, metodológicas y contextuales en la investigación sobre inteligencia artificial en educación superior, así como la colaboración interdisciplinaria. Desde esta perspectiva, la formación docente debe permitir examinar los supuestos de las herramientas y valorar sus resultados, además de aprender a utilizarlas.

Los dilemas éticos atraviesan todo este proceso. Decidir qué información se recoge, con qué finalidad se analiza y quién puede acceder a ella implica distribuir responsabilidades y poder dentro de las instituciones educativas. Slade y Prinsloo (2013) destacaron problemas relacionados con el consentimiento informado, la privacidad, la interpretación de los datos y la vigilancia. Su planteamiento invita a reconocer al estudiante como una persona cuya

trayectoria cambia y depende del contexto, evitando reducir su identidad a un perfil calculado. Así, la evaluación ética debe acompañar el diseño y el uso de los sistemas, desde la selección de los datos hasta las consecuencias de las decisiones adoptadas.

La equidad constituye otra dimensión decisiva. Los sistemas algorítmicos pueden producir resultados diferentes entre grupos y reproducir desigualdades presentes en los datos o en las condiciones de implementación. Baker y Hawn (2022) documentaron evidencia de sesgos educativos asociados con distintas características de los estudiantes y examinaron cómo estos pueden introducirse en diversas etapas del desarrollo y despliegue de los algoritmos. Su análisis muestra la necesidad de evaluar quiénes se benefician, quiénes quedan insuficientemente representados y sobre quiénes recaen los errores. Desde esta perspectiva, una medida global de desempeño resulta insuficiente para juzgar la pertinencia educativa de un sistema. La discusión también requiere distinguir niveles educativos y condiciones institucionales. La revisión de Sousa et al. (2021) encontró que las aplicaciones de analítica en secundaria se concentraban en iniciativas de pequeña escala, lo que limita la extrapolación de experiencias universitarias al ámbito escolar. A su vez, el Informe de Seguimiento de la Educación en el Mundo de 2023 subraya que la incorporación de tecnología debe examinarse considerando su pertinencia, equidad y sostenibilidad (Global Education Monitoring Report Team, 2023). Para el análisis de los contextos latinoamericanos y ecuatorianos, estos criterios ofrecen un punto de partida: corresponde estudiar las condiciones locales antes de asumir que una solución desarrollada en otro entorno responderá a las mismas necesidades.

La expansión de la inteligencia artificial generativa añade nuevas preguntas sobre el tratamiento de información estudiantil, la fiabilidad de las respuestas y la autonomía de quienes aprenden. Aunque estas herramientas no representan la totalidad de la inteligencia artificial educativa ni sustituyen a la analítica del aprendizaje, su incorporación exige examinar cómo se combinan con los sistemas de seguimiento y personalización. Miao y Holmes (2023) proponen una orientación centrada en las personas, con atención a la privacidad, la inclusión y la capacidad humana de decisión. Este enfoque permite situar la innovación tecnológica dentro de una discusión más amplia sobre los fines de la educación. A partir de estas tensiones, esta obra tiene como propósito analizar los fundamentos, las aplicaciones y los dilemas éticos de la convergencia entre analítica del aprendizaje e inteligencia artificial. La pregunta que orienta el proyecto es bajo qué condiciones la predicción y la personalización pueden

contribuir a mejorar la educación, proteger los derechos de los estudiantes y sostener decisiones pedagógicas justificadas. El desarrollo del libro articulará tres ejes: la interpretación de los datos educativos, la relación entre predicciones e intervenciones y la responsabilidad ética e institucional en el uso de estas tecnologías. Su contribución será ofrecer criterios para que docentes, investigadores y responsables educativos puedan valorar las herramientas según la evidencia que las respalda, su adecuación al contexto y las consecuencias de su utilización.

Capítulo 1
Fundamentos de la analítica del aprendizaje y la inteligencia artificial en educación

Del registro de información a la comprensión del aprendizaje.

La educación ha recurrido históricamente a registros para documentar la asistencia, valorar el desempeño y organizar las trayectorias de los estudiantes. La expansión de los entornos digitales ha ampliado la cantidad y diversidad de esa información: junto con las calificaciones y las entregas de tareas, es posible registrar secuencias de navegación, respuestas a ejercicios, participación en actividades y uso de recursos. La analítica del aprendizaje surge en este escenario como un campo que busca interpretar los datos educativos para comprender los procesos formativos y apoyar decisiones. Su desarrollo plantea una exigencia fundamental: vincular los procedimientos de análisis con el conocimiento disponible sobre cómo aprenden las personas (Gašević et al., 2015).

Esta vinculación requiere reconocer que un registro digital constituye una representación parcial de una actividad. Acceder a un documento, permanecer conectado o responder una pregunta son acontecimientos observables; comprender una explicación, reorganizar conocimientos o desarrollar una estrategia de estudio son procesos cuya interpretación exige evidencias adicionales. El desafío consiste en establecer relaciones justificadas entre lo que el sistema registra y aquello que se pretende conocer. Gašević et al. (2015) advierten que los componentes computacionales de la analítica deben integrarse con la investigación educativa para contribuir de manera sostenida al estudio y la mejora del aprendizaje. Desde esta perspectiva, la disponibilidad de información abre posibilidades de indagación, pero también obliga a examinar sus límites.

Del dato al significado pedagógico

Para explicar este tránsito, resulta útil distinguir entre registro, indicador e interpretación. En este apartado se entiende por registro la evidencia documentada de un acontecimiento, como una respuesta o una entrega; por indicador, una medida construida a partir de uno o varios registros; y por interpretación pedagógica, la explicación razonada de lo que esa medida podría expresar en una situación educativa. Esta distinción permite hacer visibles las

decisiones que median entre la actividad del estudiante y las conclusiones que se formulan sobre ella. Es una organización conceptual coherente con los marcos que sitúan los objetivos, los actores, los datos y las condiciones de uso entre los componentes de la analítica del aprendizaje (Greller & Drachsler, 2012).

Considérese un ejemplo hipotético: una plataforma registra que una estudiante abrió diez veces un mismo recurso durante una semana. El número de accesos puede convertirse en un indicador de frecuencia de consulta, pero todavía no permite determinar por qué se produjo esa conducta. La estudiante pudo revisar el material para consolidar conocimientos, buscar una respuesta específica o intentar comprender una explicación que le resultaba confusa. También pudo haber experimentado interrupciones de conectividad. Cada posibilidad plantea una interpretación diferente y, por tanto, una respuesta docente distinta. El ejemplo muestra por qué conviene formular las conclusiones como hipótesis que deben contrastarse con otras evidencias.

La selección de un indicador también incorpora una decisión sobre qué se considera relevante. Si se utiliza la cantidad de intervenciones en un foro para representar la participación, se privilegia su frecuencia; si se examinan las razones aportadas, la relación entre argumentos o la revisión de una postura, se atiende a otras dimensiones. Greller y Drachsler (2012) proponen un marco que ayuda a reconocer que la explotación de datos educativos depende de propósitos y condiciones que deben hacerse explícitos. Aplicado al ejemplo, esto significa que el docente necesita definir primero qué dimensión de la participación desea comprender y después valorar qué registros permiten aproximarse a ella.

Tabla 1

Registros educativos y precauciones para su interpretación pedagógica

Registro disponible	Indicador posible	Interpretación que requiere cautela	Evidencia complementaria pertinente
Accesos al aula virtual	Frecuencia de ingreso	Interpretar pocos accesos como falta de interés	Condiciones de conectividad, trabajo fuera de la plataforma y organización del curso
Apertura y consulta de recursos	Número de consultas o tiempo registrado	Equiparar permanencia con comprensión	Explicaciones del estudiante, resolución de problemas y aplicación de conceptos
Respuestas a un cuestionario	Porcentaje de aciertos y patrones de error	Atribuir todo error al desconocimiento del contenido	Justificación de respuestas y revisión de la claridad y dificultad de las preguntas
Intervenciones en un foro	Frecuencia de publicaciones	Asociar mayor cantidad con mejor participación	Calidad argumentativa, pertinencia e interacción con las ideas de otros
Entregas de actividades	Cumplimiento y puntualidad	Explicar el retraso únicamente por desorganización	Carga de trabajo, comprensión de instrucciones y circunstancias personales
Cambios entre versiones de una tarea	Frecuencia y tipo de revisión	Suponer que cualquier modificación refleja mejora	Comparación del contenido con criterios explícitos y explicación de los cambios

Nota. Elaboración propia con ejemplos hipotéticos, basada en la necesidad de relacionar los datos con los propósitos educativos y los procesos de aprendizaje discutida por Gašević et al. (2015) y Greller y Drachsler (2012). Las relaciones de la tabla orientan el análisis; no constituyen reglas diagnósticas ni indicadores validados.

La pregunta educativa como punto de partida

El valor de los datos depende, en buena medida, de la pregunta que organiza su análisis. Preguntar cuántas veces se consultó un recurso permite describir una conducta; preguntar qué dificultades persisten después de utilizarlo exige examinar respuestas, producciones o explicaciones. Ambas preguntas pueden ser pertinentes, pero producen conocimientos diferentes. Un análisis orientado a mejorar la enseñanza debe precisar qué decisión podría apoyarse en sus resultados y qué información se necesita para justificarla. Ifenthaler et al. (2021) sitúan las necesidades de los distintos usuarios y el diseño centrado en las personas entre los asuntos que requieren atención en el desarrollo de la analítica del aprendizaje.

Como propuesta de trabajo para este libro, el recorrido puede comenzar con una dificultad educativa delimitada. Por ejemplo, un docente observa que sus estudiantes resuelven ejercicios rutinarios, pero encuentran problemas al justificar el procedimiento. A partir de esa observación, puede reunir producciones, examinar errores recurrentes y contrastarlos con explicaciones orales o escritas. La información obtenida orientaría una intervención centrada en la argumentación y permitiría evaluar posteriormente si las justificaciones mejoraron. Este recorrido establece una relación explícita entre el problema, las evidencias y la decisión pedagógica.

La presentación de resultados también necesita responder a esa relación. Un panel con gráficos puede facilitar la consulta de información, aunque su utilidad depende de que el usuario comprenda qué representan las medidas y qué acciones puede considerar. En una revisión de estudios sobre paneles de analítica, Matcha et al. (2020) identificaron limitaciones en su fundamentación desde el aprendizaje autorregulado y en la evaluación de sus efectos. Estos hallazgos cuestionan la expectativa de que mostrar datos al estudiante produzca, por sí mismo, una reflexión útil o una modificación de sus estrategias. La representación visual requiere un propósito formativo y orientaciones que permitan actuar sobre la información.

Comprender el aprendizaje en su contexto

La interpretación de los datos debe considerar las características de la actividad y las oportunidades reales de participación. En un ejemplo hipotético, dos estudiantes pueden registrar el mismo tiempo de conexión y haber realizado trabajos distintos: uno mantiene abierta una lectura mientras elabora apuntes; otro consulta brevemente el documento y continúa estudiando una copia descargada. Una diferencia en el registro puede responder al modo de utilizar la tecnología, sin expresar necesariamente una diferencia equivalente en el aprendizaje. Estas situaciones justifican contrastar las huellas digitales con evidencias del trabajo realizado y con información sobre las condiciones de estudio.

La necesidad de contextualización tiene respaldo en investigaciones latinoamericanas. Hilliger et al. (2020) estudiaron las prácticas y políticas relacionadas con los datos en cuatro universidades, dos chilenas y dos ecuatorianas, mediante un diseño de métodos mixtos. Sus resultados identificaron oportunidades para incorporar servicios de analítica, junto con dificultades vinculadas con la fiabilidad de los sistemas de información y la existencia de políticas para regular su uso. El estudio permite reconocer que la capacidad de aprovechar los registros depende de condiciones organizativas y de gestión. Su alcance corresponde a las instituciones examinadas y no autoriza a atribuir las mismas características a todas las universidades de ambos países.

La producción regional también ofrece antecedentes para construir una discusión situada. Cechinel et al. (2020) analizaron 282 publicaciones de autores latinoamericanos correspondientes al período 2011–2019. Su revisión organizó los trabajos según dimensiones como los datos utilizados, los actores destinatarios, los objetivos, las técnicas, la madurez de las herramientas y las cuestiones éticas. Este aporte documenta la existencia de una trayectoria regional de investigación y permite examinar su diversidad. Al tratarse de un mapeo de publicaciones, sus resultados describen el desarrollo del campo durante el período estudiado; no demuestran por sí mismos la efectividad educativa de las aplicaciones identificadas.

En Ecuador, Zúñiga-Prieto et al. (2020) presentaron dos estudios de caso sobre la aplicación del marco LALA para desarrollar y adoptar herramientas de analítica en instituciones de educación superior. El trabajo destacó la necesidad de ajustar las actividades de implementación a las condiciones de cada institución. Su contribución resulta pertinente para este apartado porque muestra que el

uso de datos educativos exige decisiones sobre necesidades, políticas, capacidades y herramientas. La experiencia aporta orientaciones para la adopción institucional, aunque su diseño y alcance deben distinguirse de una evaluación causal de mejoras en el aprendizaje.

La interpretación como responsabilidad compartida

La comprensión de los datos requiere capacidades que involucran a docentes, estudiantes, equipos técnicos y responsables institucionales. Ifenthaler et al. (2021) identifican la alfabetización en datos, la actualización de políticas, la calidad de la información y el diseño centrado en los usuarios como áreas de actuación. Para el trabajo educativo, estas capacidades incluyen reconocer cómo se construyó una medida, qué aspectos deja fuera y qué conclusiones permite sostener. También implican comunicar la incertidumbre de los resultados y ofrecer condiciones para que las personas participen en su interpretación.

Desde el planteamiento de este libro, la participación del estudiante puede contribuir a contrastar las interpretaciones que se elaboran sobre su actividad. Si un sistema señala una disminución de entregas, resulta pertinente explorar con la persona qué está ocurriendo antes de atribuirle una causa. La conversación puede revelar dificultades de comprensión, problemas de acceso o circunstancias que el registro no contiene. Del mismo modo, el docente puede identificar desajustes entre la información presentada y la secuencia didáctica. Se propone, por ello, una lectura compartida en la que los resultados analíticos funcionen como evidencias abiertas al examen y a la revisión.

Pasar del registro de información a la comprensión del aprendizaje supone construir una explicación que pueda justificarse y ponerse a prueba. El proceso requiere precisar la pregunta educativa, seleccionar evidencias pertinentes, explicitar las limitaciones de los indicadores y valorar sus implicaciones para la enseñanza. Con esta base, la analítica puede contribuir a reconocer dificultades y orientar apoyos, siempre que sus resultados se interpreten en relación con las personas y los contextos de los que proceden. Esta delimitación permite avanzar hacia el siguiente apartado, dedicado a distinguir la analítica del aprendizaje, la minería de datos educativos y la inteligencia artificial.

Analítica del aprendizaje, minería de datos educativos e inteligencia artificial: diferencias y relaciones.

La analítica del aprendizaje, la minería de datos educativos y la inteligencia artificial comparten métodos y aplicaciones, pero representan campos con propósitos y alcances diferentes. Su distinción permite comprender qué hace una herramienta, qué conocimientos produce y cómo pueden utilizarse sus resultados. Romero y Ventura (2020) describen una relación de proximidad entre la analítica y la minería de datos educativos, cuyas comunidades han desarrollado enfoques complementarios para estudiar la información generada en los procesos formativos. Sus fronteras son permeables: una misma investigación puede utilizar técnicas de ambos campos.

La analítica del aprendizaje se orienta a interpretar información sobre los estudiantes y sus entornos para apoyar la comprensión y mejora de los procesos educativos. Comprende actividades como la elaboración de indicadores, la visualización de trayectorias y la comunicación de resultados a docentes o estudiantes. En América Latina, Cechinel et al. (2020) documentaron la diversidad de este campo mediante un mapeo de investigaciones que consideró los datos utilizados, sus destinatarios, los objetivos y las técnicas empleadas. Esta diversidad muestra que la analítica no se define por un algoritmo específico, sino por la articulación entre información, propósitos educativos y posibilidades de actuación.

La minería de datos educativos concentra su atención en desarrollar y aplicar métodos para descubrir patrones en información procedente de contextos educativos. Puede emplear clasificación, agrupamiento, análisis de asociaciones o modelos predictivos para estudiar el desempeño y las actividades de los estudiantes. La diferencia con la analítica es principalmente de énfasis: mientras la minería presta especial atención al descubrimiento y modelado de patrones, la analítica suele destacar su interpretación y utilización por los actores educativos. Esta distinción no implica que la minería excluya la pedagogía ni que la analítica prescinda de métodos computacionales avanzados (Romero & Ventura, 2020).

La inteligencia artificial abarca un conjunto más amplio de métodos y sistemas que permiten realizar tareas como reconocer patrones, formular recomendaciones, procesar lenguaje o adaptar respuestas. En educación, sus aplicaciones incluyen la evaluación automatizada, la tutoría inteligente y los sistemas adaptativos, además de la predicción del desempeño. Por ello, su

relación con los otros campos es de intersección: determinadas técnicas de inteligencia artificial pueden utilizarse en la minería de datos y en la analítica, aunque estas también recurren a procedimientos estadísticos y visualizaciones que no requieren sistemas de IA. Asimismo, una aplicación educativa de inteligencia artificial puede centrarse en ofrecer tutoría sin tener como función principal comunicar resultados analíticos a una institución (Zawacki-Richter et al., 2019).

Tabla 2

Diferencias de énfasis entre los tres campos

Campo	Propósito predominante	Ejemplo ilustrativo
Analítica del aprendizaje	Interpretar y comunicar información para comprender y apoyar los procesos educativos	Un panel que permite al docente revisar dificultades y organizar apoyos
Minería de datos educativos	Descubrir y modelar patrones en datos educativos	Un análisis que identifica secuencias de errores recurrentes
Inteligencia artificial en educación	Desarrollar sistemas que realizan tareas de reconocimiento, recomendación, adaptación o interacción	Un tutor que selecciona ejercicios según las respuestas del estudiante

Nota. Elaboración propia a partir de Romero y Ventura (2020) y Zawacki-Richter et al. (2019). Los ejemplos son hipotéticos y los propósitos descritos no constituyen límites excluyentes.

Un ejemplo permite comprender su complementariedad. Ante dificultades persistentes en matemáticas, la minería de datos podría identificar combinaciones de errores presentes en las respuestas; un sistema de inteligencia artificial podría utilizar esa información para recomendar ejercicios; y una herramienta de analítica podría presentar al docente los avances y las dificultades del grupo. Estas funciones pueden coexistir en una misma plataforma. Para valorar su pertinencia, corresponde examinar por separado la calidad del patrón identificado, la adecuación de la recomendación y la utilidad de la información presentada.

Los aportes latinoamericanos también han contribuido a ampliar las fuentes de información consideradas. Desde la Escuela Superior Politécnica del Litoral, en

Ecuador, Ochoa (2017) desarrolló una aproximación a la analítica multimodal que integra registros de plataformas con producciones y señales como escritura, habla, gestos o mirada. Su propuesta busca combinar evidencias complementarias para comprender mejor las actividades de aprendizaje. Este enfoque muestra que el campo puede estudiar experiencias presenciales y prácticas que trascienden la navegación digital. La incorporación de estas fuentes exige justificar su pertinencia y evitar atribuirles un significado pedagógico automático.

La integración de los tres campos depende, además, de capacidades institucionales. En universidades chilenas y ecuatorianas, Hilliger et al. (2020) identificaron oportunidades para incorporar analítica junto con dificultades relacionadas con la fiabilidad de los sistemas de información y las políticas de uso de datos. Estos resultados sitúan la discusión en condiciones concretas: disponer de algoritmos no resuelve por sí solo los problemas de organización, interpretación y responsabilidad. Para este libro, la distinción conceptual permitirá examinar cada aplicación según su finalidad educativa, sus métodos y la evidencia que respalda sus resultados, evitando tratar como equivalentes el descubrimiento de patrones, la recomendación automatizada y la mejora del aprendizaje.

Tipos de analítica: descriptiva, diagnóstica, predictiva y prescriptiva.

La analítica del aprendizaje puede organizarse según cuatro propósitos: describir lo ocurrido, explorar sus posibles explicaciones, anticipar resultados y recomendar acciones. Esta clasificación permite precisar qué conocimiento ofrece un análisis y qué decisiones puede respaldar. Los tipos pueden combinarse en una misma herramienta, aunque responden a preguntas diferentes y requieren evidencias acordes con sus objetivos (Paulsen & Lindsay, 2024). En la literatura latinoamericana, Sánchez-Mendiola et al. (2019) también distinguen funciones descriptivas, predictivas y prescriptivas al examinar las aplicaciones de la analítica en educación médica.

La analítica descriptiva organiza y sintetiza información sobre actividades y resultados educativos. Puede mostrar la distribución de calificaciones, la frecuencia de participación o la evolución de las entregas. Su contribución consiste en hacer visibles tendencias y diferencias que requieren atención, sin explicar necesariamente sus causas. Sánchez-Mendiola et al. (2019) sitúan esta función entre las posibilidades de utilizar datos para comprender y dar seguimiento a los procesos formativos. Un informe descriptivo resulta útil

cuando permite reconocer un problema relevante y delimitar qué información adicional se necesita.

La analítica diagnóstica examina factores y relaciones que podrían ayudar a explicar los resultados observados. Puede comparar patrones de error, características de las actividades o condiciones de participación (Paulsen & Lindsay, 2024). Su denominación exige una precaución metodológica: encontrar una asociación no demuestra una relación causal. Por ejemplo, si quienes consultan menos recursos obtienen calificaciones inferiores, todavía debe investigarse si intervienen conocimientos previos, dificultades de acceso u otras condiciones. La revisión de Romero y Ventura (2020) permite reconocer la variedad de procedimientos disponibles para estudiar relaciones en datos educativos; la interpretación de esas relaciones debe ajustarse al diseño de cada investigación.

La analítica predictiva estima resultados todavía desconocidos a partir de información disponible. Entre sus aplicaciones se encuentran la anticipación del desempeño y la identificación de estudiantes que podrían necesitar apoyo. Para ello pueden utilizarse procedimientos estadísticos y técnicas de aprendizaje automático (Romero & Ventura, 2020). La estimación resultante depende de los datos y de las condiciones bajo las cuales se desarrolló y validó el modelo. En consecuencia, una alerta debe interpretarse como una señal para examinar la situación y organizar acompañamiento; convertirla en una etiqueta permanente excedería su alcance.

La analítica prescriptiva utiliza información para recomendar cursos de acción orientados a un objetivo. Puede proponer actividades de refuerzo, recursos o apoyos diferenciados (Sánchez-Mendiola et al., 2019). Conviene distinguir, sin embargo, entre formular una recomendación y demostrar que esta produce el beneficio esperado. Una sugerencia generada mediante reglas docentes o modelos computacionales necesita una justificación pedagógica y una evaluación de sus resultados. Además, identificar quién podría presentar dificultades y determinar qué apoyo le beneficiaría son problemas diferentes: la capacidad predictiva de un sistema no demuestra por sí misma la efectividad de su intervención.

Tabla 3

Propósitos y límites de los tipos de analítica del aprendizaje

Tipo	Pregunta orientadora	Ejemplo hipotético	Límite principal
Descriptiva	¿Qué ocurrió o está ocurriendo?	Mostrar que aumentaron las tareas incompletas	No explica por sí sola el aumento
Diagnóstica	¿Qué factores podrían explicarlo?	Examinar errores, instrucciones y condiciones de entrega	Las asociaciones no prueban causalidad
Predictiva	¿Qué resultado es probable?	Estimar el riesgo de no completar una asignatura	La estimación puede fallar y requiere validación
Prescriptiva	¿Qué acción conviene considerar?	Recomendar tutoría o actividades de refuerzo	La recomendación no garantiza efectividad

Nota. Elaboración propia a partir de Paulsen y Lindsay (2024), Romero y Ventura (2020) y Sánchez-Mendiola et al. (2019). Los ejemplos ilustran funciones analíticas; no representan resultados de una investigación.

En la práctica, estas funciones pueden articularse alrededor de una dificultad concreta. En un caso hipotético de comprensión lectora, el análisis descriptivo identificaría errores frecuentes; el diagnóstico exploraría las habilidades y condiciones relacionadas; el predictivo estimaría la probabilidad de dificultades posteriores; y el prescriptivo sugeriría apoyos. La evaluación posterior permitiría examinar si estos fueron pertinentes. Esta articulación exige conservar la diferencia entre observar, explicar, anticipar y recomendar, pues cada operación respalda conclusiones distintas.

Su implementación también depende de capacidades institucionales. Hilliger et al. (2020), en un estudio realizado en universidades chilenas y ecuatorianas, identificaron dificultades vinculadas con la fiabilidad de los sistemas de información y las políticas para utilizar los datos. Estos hallazgos permiten situar la clasificación en condiciones reales: incorporar predicciones o recomendaciones exige información adecuada, responsabilidades definidas y capacidad de respuesta. Por ello, este libro propone seleccionar el tipo de

analítica según la pregunta educativa y la decisión que se necesita fundamentar. La sofisticación técnica adquiere sentido cuando contribuye a ofrecer un apoyo pertinente y evaluable.

Datos, indicadores y modelos: cómo se construye una representación del estudiante.

Los sistemas de analítica construyen representaciones del estudiante mediante la selección y transformación de información sobre sus actividades, resultados y condiciones de participación. Estas representaciones permiten examinar determinados aspectos de su trayectoria, pero su alcance depende de las decisiones tomadas durante el análisis. Elegir qué datos recoger, cómo agruparlos y qué significado atribuirles determina aquello que el sistema puede mostrar. Goldhammer et al. (2021) señalan que interpretar indicadores derivados de registros digitales exige justificar las inferencias realizadas sobre los procesos del estudiante. Por ello, comprender un resultado analítico requiere conocer cómo se produjo y qué evidencias respaldan su interpretación.

Los datos educativos pueden proceder de fuentes diversas: sistemas administrativos, evaluaciones, plataformas de aprendizaje, cuestionarios o producciones académicas. Cada fuente responde a condiciones y propósitos particulares. Una calificación sintetiza un desempeño según determinados criterios; un registro de navegación documenta una interacción con el sistema; y un cuestionario recoge respuestas del estudiante sobre su experiencia. La integración de estas fuentes amplía las posibilidades de análisis, aunque requiere revisar su estructura, procedencia y relación con el problema educativo investigado (Romero & Ventura, 2020). Esta revisión evita tratar como equivalentes evidencias que describen dimensiones distintas de la actividad formativa.

Antes de elaborar indicadores, los datos suelen atravesar procesos de preparación: identificación de registros duplicados, revisión de valores ausentes, organización temporal y selección de variables. Estas operaciones afectan los resultados y deben documentarse (Romero & Ventura, 2020). Considérese un ejemplo hipotético: si una plataforma permanece abierta durante una hora, el sistema debe establecer qué parte de ese intervalo se interpretará como tiempo de actividad. Contar toda la sesión o excluir períodos de inactividad producirá medidas diferentes. La decisión necesita explicitarse para que el indicador pueda comprenderse, compararse y revisarse.

Un indicador constituye una medida seleccionada para representar una dimensión relevante. Su construcción implica operacionalizar un concepto, es decir, precisar mediante qué evidencias se intentará estudiarlo. Conceptos como participación, autonomía o autorregulación abarcan procesos que no son directamente equivalentes a una frecuencia de acceso o a una cantidad de tareas. Goldhammer et al. (2021) explican que el tránsito desde los registros hacia indicadores de proceso exige razonamiento sustentado en evidencias. En consecuencia, nombrar una medida como «compromiso» o «planificación» requiere una justificación adicional a su disponibilidad técnica.

Para ilustrarlo, podría calcularse un indicador de regularidad del estudio a partir de la distribución semanal de actividades. Esta medida mostraría si las interacciones registradas se concentran o se distribuyen en el tiempo. Atribuirle el significado de una buena planificación exigiría contrastar otras posibilidades: el curso podría imponer entregas concentradas, el estudiante podría trabajar fuera de la plataforma o disponer de acceso únicamente ciertos días. El ejemplo permite distinguir la propiedad observada —la distribución temporal— del proceso que se pretende inferir —la planificación—. También muestra por qué un indicador debe interpretarse en relación con el diseño de las actividades.

Una contribución latinoamericana que aborda esta relación es el estudio de Maldonado-Mahauad et al. (2018), desarrollado con participación de investigadores de la Pontificia Universidad Católica de Chile y la Universidad de Cuenca. Los autores combinaron el análisis de secuencias de interacción de 3.458 participantes en tres cursos masivos abiertos en línea con instrumentos de autoinforme sobre aprendizaje autorregulado. Identificaron seis patrones de secuencias y examinaron su relación con estrategias descritas en la literatura. El aporte metodológico consiste en conectar las huellas de actividad con referentes teóricos y otra fuente de información, en lugar de interpretar las secuencias de manera aislada. Sus resultados corresponden a los cursos y participantes estudiados; no constituyen perfiles universales de autorregulación.

Los modelos permiten organizar relaciones entre variables para describir patrones, estimar resultados o representar aspectos de un proceso. Pueden adoptar formas relativamente simples, como una regresión, o emplear técnicas computacionales más complejas. También pueden agrupar estudiantes según similitudes en sus registros (Romero & Ventura, 2020). Cada alternativa responde a una finalidad distinta. Un modelo que predice la aprobación de una asignatura puede ser útil para anticipar necesidades, pero no explica necesariamente cómo

se construyó el conocimiento ni qué intervención modificará el resultado. La representación debe evaluarse según el propósito para el cual se utiliza.

En un ejemplo hipotético, un sistema podría clasificar como «participación baja» a quienes realizan menos de cierto número de intervenciones. Para interpretar esa categoría habría que conocer quién definió el umbral, con qué fundamento y para qué actividad. Además, el significado cambiaría si las intervenciones fueran obligatorias, voluntarias o sustituidas por otras formas de trabajo. Desde el enfoque de este libro, los perfiles deben presentarse como descripciones condicionadas por datos, reglas y períodos específicos. Así se evita que una clasificación circunstancial se convierta en una afirmación sobre la capacidad general de la persona.

La representatividad de los datos merece una atención particular. Baker y Hawn (2022) documentan que los sesgos pueden introducirse en diferentes etapas del desarrollo y despliegue de algoritmos educativos y afectar de manera desigual a distintos grupos. Por ello, evaluar un modelo exige examinar para quién funciona, qué errores comete y cómo se distribuyen sus consecuencias. Un buen desempeño promedio puede coexistir con dificultades importantes en una población concreta. Asimismo, las variables vinculadas con las condiciones de acceso requieren cuidado: una diferencia de actividad registrada puede reflejar oportunidades desiguales de participación.

En el ámbito latinoamericano, Hilliger et al. (2020) encontraron que la fiabilidad de los sistemas de información y las políticas de uso de datos constituían desafíos para incorporar analítica en las universidades chilenas y ecuatorianas examinadas. Este hallazgo subraya que la calidad de una representación depende también de la infraestructura y de las prácticas institucionales que la sostienen. La documentación de las fuentes, los criterios de transformación y las limitaciones debería acompañar a los resultados, de modo que docentes y responsables educativos puedan valorar su pertinencia.

La discusión sobre modelos también exige conservar una concepción amplia del aprendizaje. Guzmán-Valenzuela et al. (2021), desde instituciones chilenas, analizaron 385 publicaciones e identificaron una persistente tensión entre el desarrollo de procedimientos analíticos y la atención a los procesos educativos. Su revisión advierte sobre el riesgo de privilegiar aquello que puede cuantificarse sin examinar suficientemente su significado formativo. Para el presente capítulo, esta observación conduce a un criterio central: las representaciones del estudiante deben mantenerse abiertas al contraste con sus

producciones, las condiciones de enseñanza y su propia explicación de la experiencia. Su utilidad reside en orientar preguntas y apoyos justificados, reconociendo que siempre ofrecen una aproximación parcial y revisable.

Fundamentos pedagógicos: evaluación formativa, autorregulación y aprendizaje situado.

La incorporación de analítica del aprendizaje e inteligencia artificial requiere explicitar qué se entiende por aprender y mediante qué procesos se espera favorecerlo. Una herramienta puede identificar diferencias de desempeño o recomendar actividades, pero su pertinencia educativa depende de la relación entre sus funciones, los objetivos de enseñanza y las necesidades de los estudiantes. Desde instituciones chilenas, Guzmán-Valenzuela et al. (2021) advierten que el desarrollo de la analítica ha prestado una atención insuficiente a la complejidad del aprendizaje. Esta observación plantea la necesidad de utilizar la teoría pedagógica para orientar la selección de evidencias y las intervenciones, además de interpretar los resultados.

La evaluación formativa ofrece un primer fundamento para establecer esa relación. Black y Wiliam (2009) sitúan las prácticas formativas dentro de una comprensión amplia de la pedagogía, vinculada con la interacción en el aula y la regulación del aprendizaje. Desde esta perspectiva, recoger información adquiere sentido cuando contribuye a decidir cómo continuar la enseñanza y el trabajo del estudiante. La aplicación frecuente de cuestionarios o la generación automática de informes necesita, por tanto, acompañarse de oportunidades para interpretar las dificultades y actuar sobre ellas.

En este marco, la retroalimentación constituye una mediación entre la evidencia disponible y las posibilidades de mejora. Anijovich y Cappelletti (2020), referentes argentinas del campo de la evaluación, examinan su contribución tanto al aprendizaje como a la enseñanza. Su planteamiento permite situar la devolución de información dentro de un proceso formativo, en el que importa qué se comunica y cómo puede utilizarse. Aplicado a la analítica, esto exige transformar los indicadores en orientaciones comprensibles y pertinentes para la actividad, evitando que la comunicación se reduzca a señalar una posición o una carencia.

Un ejemplo hipotético permite precisar esta diferencia. Ante un texto con dificultades argumentativas, informar que el desempeño es «bajo» aporta una valoración general. Una devolución que identifica la ausencia de evidencias,

muestra un fragmento concreto y solicita revisar la relación entre afirmación y fundamento ofrece una vía de trabajo. Para este libro, el criterio pedagógico será examinar si la información ayuda a reconocer qué se necesita mejorar, si el estudiante dispone de recursos para hacerlo y si existe una oportunidad posterior de revisión. Una respuesta automatizada también debe someterse a estos criterios y contrastarse con la producción evaluada.

El aprendizaje autorregulado aporta un segundo fundamento. Panadero (2017), en su revisión de seis modelos, lo presenta como un campo que integra dimensiones cognitivas, metacognitivas, conductuales, motivacionales y emocionales. Comprende procesos mediante los cuales los estudiantes orientan su actividad hacia metas, supervisan su avance y ajustan sus estrategias. Aunque los modelos difieren en su organización, permiten comprender el estudio como una actividad dinámica. Esta perspectiva evita reducir la autonomía a una característica fija de la persona o equipararla con el cumplimiento de instrucciones.

La relación con la analítica puede establecerse alrededor de la planificación, el seguimiento y la reflexión. Desde la propuesta de este capítulo, una herramienta orientada a la planificación podría ayudar a formular metas y distribuir actividades; durante el trabajo, podría facilitar la revisión de avances; y al finalizar, permitir comparar lo previsto con lo realizado. Su valor debería examinarse según las oportunidades que ofrece para comprender y ajustar el propio aprendizaje. La recomendación automática de una siguiente tarea, por sí sola, deja abierta la pregunta de si el estudiante reconoce por qué se propone y cómo se relaciona con su objetivo.

Esta precaución encuentra respaldo en la revisión de Matcha et al. (2020), que identificó limitaciones en la fundamentación teórica y la evaluación de paneles de analítica desde la perspectiva del aprendizaje autorregulado. Sus resultados cuestionan la suposición de que mostrar datos sobre la actividad basta para apoyar la metacognición. Para orientar el diseño, corresponde examinar qué proceso se desea favorecer —por ejemplo, establecer metas o revisar una estrategia— y qué función concreta de la herramienta podría contribuir a ello.

La investigación latinoamericana ofrece experiencias que relacionan las trazas digitales con estos fundamentos. Maldonado-Mahauad et al. (2018), con participación de investigadores de Chile y Ecuador, combinaron secuencias de interacción en cursos masivos abiertos en línea con instrumentos de autoinforme sobre autorregulación. Su estudio ilustra una forma de contrastar evidencias de

comportamiento con referentes teóricos e información aportada por los participantes. Este enfoque resulta relevante porque un registro de actividad puede admitir distintas interpretaciones; examinarlo desde varias fuentes fortalece la discusión sobre los procesos que podría representar.

El aprendizaje situado introduce una tercera perspectiva. Díaz Barriga Arceo (2003), desde la Universidad Nacional Autónoma de México, explica que el conocimiento forma parte de la actividad, el contexto y la cultura en los que se desarrolla. Destaca la mediación y la construcción conjunta de significados, y propone estrategias como el análisis de casos, los proyectos y la resolución de problemas auténticos. Esta aproximación invita a estudiar el desempeño en relación con las prácticas y herramientas que permiten producirlo.

Aplicar esta perspectiva a la analítica supone examinar cómo se organiza la situación de aprendizaje. En un proyecto colaborativo hipotético, contar intervenciones individuales ofrecería información limitada sobre la contribución de cada integrante. Sería pertinente considerar también la elaboración de argumentos, la revisión de acuerdos, la integración de aportes y la calidad de la producción conjunta. Estos criterios son una propuesta de análisis derivada del enfoque situado: las evidencias deben corresponder a la actividad y a sus objetivos. La comparación entre estudiantes requiere, además, reconocer las oportunidades de participación que tuvieron.

La perspectiva situada también permite cuestionar recomendaciones desconectadas del problema educativo. Si un estudiante necesita interpretar información en una situación profesional o comunitaria, recomendar ejercicios aislados puede resultar insuficiente. Díaz Barriga Arceo (2003) subraya la relevancia de actividades social y culturalmente significativas. Para el diseño de apoyos con inteligencia artificial, esto orienta una pregunta concreta: ¿la adaptación propuesta ayuda a participar mejor en la práctica que se pretende aprender? La respuesta requiere valorar el contenido, las condiciones de realización y el tipo de razonamiento que la actividad demanda.

Los tres fundamentos pueden articularse en una misma experiencia. En un caso hipotético de análisis de un problema ambiental local, el enfoque situado orientaría la selección de una tarea relevante; la evaluación formativa permitiría recoger evidencias y ajustar los apoyos durante su desarrollo; y la autorregulación ayudaría a planificar, supervisar y revisar el trabajo. La analítica podría facilitar el seguimiento de versiones y dificultades, mientras una herramienta de inteligencia artificial podría ofrecer preguntas o recursos que el

docente y los estudiantes valorarían según su pertinencia. La intervención tendría así un propósito pedagógico identificable y resultados que podrían examinarse.

Desde este planteamiento, fundamentar pedagógicamente la analítica implica mantener una relación explícita entre objetivos, actividades, evidencias y decisiones. La evaluación formativa orienta el uso de la información para mejorar el trabajo en curso; la autorregulación permite examinar cómo participa el estudiante en la conducción de su aprendizaje; y el enfoque situado ayuda a interpretar el desempeño dentro de las condiciones que lo hacen posible. Estos fundamentos ofrecen criterios para valorar las tecnologías según su contribución educativa y preparan la discusión del siguiente apartado sobre la calidad de los datos y la validez de las interpretaciones.

Calidad de los datos y validez de las interpretaciones: límites de lo que puede medirse.

La utilidad educativa de la analítica depende de la calidad de los datos y de la justificación de las conclusiones que se construyen a partir de ellos. Estas condiciones están relacionadas, pero deben examinarse por separado. Un conjunto de registros puede estar completo y correctamente organizado, mientras que su interpretación sobre el aprendizaje puede ser insuficiente. Goldhammer et al. (2021) sostienen que los indicadores derivados de registros digitales requieren argumentos teóricos y evidencias empíricas que respalden los significados atribuidos. La calidad técnica de la información constituye, por tanto, una condición necesaria que debe complementarse con una evaluación de sus usos educativos.

Examinar la calidad de los datos implica revisar su exactitud, integridad, consistencia y pertinencia temporal. Para este capítulo, estos criterios se traducen en preguntas prácticas: ¿los registros corresponden a las actividades realizadas?, ¿existen omisiones relevantes?, ¿las variables conservan el mismo significado entre asignaturas?, ¿la información está disponible cuando todavía permite intervenir? En universidades chilenas y ecuatorianas, Hilliger et al. (2020) identificaron dificultades relacionadas con la fiabilidad de los sistemas de información y las políticas para utilizar los datos. Sus resultados muestran que el aprovechamiento de la analítica depende también de prácticas institucionales que permitan mantener información interpretable y utilizable.

La ausencia de un registro merece especial atención porque admite distintas explicaciones. En un ejemplo hipotético, una actividad sin calificación podría corresponder a una tarea pendiente, una entrega todavía no evaluada o un problema de sincronización. Registrar automáticamente todos estos casos como cero introduciría una interpretación que los datos disponibles no permiten sostener. De manera semejante, excluirlos del análisis podría ocultar dificultades de participación. El tratamiento debe ajustarse al significado de la ausencia y documentarse, de modo que pueda examinarse cómo afecta los resultados. La preparación de datos forma parte del proceso analítico y requiere decisiones explícitas sobre las variables y los registros utilizados (Romero & Ventura, 2020).

La validez plantea una pregunta diferente: ¿qué evidencias permiten interpretar una medida de determinada manera y utilizarla para un propósito concreto? Un indicador de tiempo de respuesta puede calcularse con exactitud, pero su significado depende de la tarea. Resolver rápidamente podría expresar dominio del contenido, una respuesta al azar o una lectura insuficiente. Goldhammer et al. (2021) destacan la necesidad de contextualizar los registros para reducir estas ambigüedades y contrastar las interpretaciones mediante estrategias de validación. El argumento debe relacionar lo observado con el proceso que se pretende estudiar y considerar explicaciones alternativas.

Desde este enfoque, conviene distinguir la consistencia de una medida de la pertinencia de su interpretación. Un sistema podría registrar de manera estable el número de mensajes publicados y, aun así, ofrecer una aproximación limitada a la calidad de la colaboración. Para valorar esa dimensión sería necesario definir qué se entiende por colaborar y qué evidencias permiten reconocerlo. Esta distinción tiene consecuencias para el uso de paneles y perfiles: una presentación precisa y visualmente clara puede facilitar la lectura, pero todavía debe justificarse qué permite concluir sobre el estudiante.

La combinación de fuentes ofrece una vía para contrastar interpretaciones, aunque tampoco garantiza por sí misma su validez. Maldonado-Mahauad et al. (2018), con participación de investigadores de Chile y Ecuador, relacionaron secuencias de interacción en cursos masivos abiertos en línea con instrumentos de autoinforme y estrategias de autorregulación descritas en la literatura. Su trabajo ilustra la posibilidad de examinar un proceso mediante evidencias complementarias. La contribución reside en hacer explícita esa relación y someterla a análisis, reconociendo que tanto las huellas digitales como las respuestas de los participantes tienen alcances específicos.

La evaluación de modelos añade la cuestión de su transferencia. Las relaciones encontradas en una asignatura o institución necesitan examinarse antes de utilizarlas en condiciones diferentes. Cambios en las actividades, los criterios de evaluación o las formas de participación pueden modificar el significado de las variables. Romero y Ventura (2020) describen la diversidad de datos, métodos y aplicaciones presentes en el campo; esta heterogeneidad exige valorar el ajuste entre el modelo y su contexto de uso. Para este libro, se propone documentar la población y el período de desarrollo, las condiciones de aplicación y las limitaciones conocidas de cada sistema.

También debe examinarse cómo se distribuyen los errores. Baker y Hawn (2022) revisan evidencia de sesgos algorítmicos en educación y muestran que estos pueden surgir en distintas etapas del desarrollo y despliegue de los sistemas. Un resultado global favorable puede ocultar diferencias entre grupos, por lo que la evaluación necesita considerar quiénes están representados y quiénes reciben resultados menos adecuados. Esta cuestión adquiere relevancia cuando las estimaciones orientan apoyos, asignación de recursos o decisiones sobre trayectorias académicas. La valoración del modelo debe incluir las consecuencias de sus errores, además de su desempeño promedio.

Un ejemplo permite precisar el problema. Si una alerta identifica dificultades que no existen, el estudiante podría recibir un seguimiento innecesario o una clasificación injustificada. Si el sistema omite a quien necesita ayuda, podría retrasar el acompañamiento. Estas situaciones hipotéticas muestran que los errores tienen consecuencias distintas según la decisión asociada. Por ello, se propone revisar la información antes de actuar y permitir que docentes y estudiantes aporten evidencias que confirmen, cuestionen o contextualicen el resultado. La posibilidad de revisión forma parte de un uso responsable de la representación analítica.

La evaluación tampoco debe terminar cuando la herramienta funciona técnicamente. Scheffel et al. (2014) desarrollaron un marco de indicadores de calidad orientado a evaluar herramientas de analítica y reunir evidencias sobre su impacto en las prácticas educativas. Este aporte amplía la discusión hacia la experiencia de uso y los resultados de la implementación. En consecuencia, corresponde distinguir entre disponer de una herramienta, utilizarla y conseguir una mejora atribuible a su incorporación. Una mayor consulta del panel puede mostrar aceptación, pero todavía requiere examinarse qué decisiones favoreció y qué efectos tuvo sobre el aprendizaje.

Los límites de la medición también afectan aquello que las instituciones consideran valioso. Si la atención se concentra exclusivamente en calificaciones, accesos o finalización de tareas, pueden quedar insuficientemente representadas dimensiones como la argumentación, la creatividad o la construcción conjunta de conocimientos. Guzmán-Valenzuela et al. (2021), desde instituciones chilenas, advierten sobre la persistencia de un énfasis analítico que no siempre incorpora suficientemente la complejidad educativa. Esta observación invita a conservar evidencias cualitativas y espacios de interpretación pedagógica, seleccionados según los objetivos de cada experiencia.

Al cerrar este capítulo, queda establecido que la analítica del aprendizaje constituye una práctica de selección, interpretación y uso de evidencias. Sus relaciones con la minería de datos educativos y la inteligencia artificial amplían las posibilidades de descripción, diagnóstico, predicción y recomendación, pero también exigen precisar los supuestos de cada operación. La construcción de indicadores y modelos requiere fundamentos pedagógicos que orienten qué observar y cómo actuar. La evaluación formativa, la autorregulación y el aprendizaje situado ofrecen referentes para mantener esa relación con los procesos educativos.

De este recorrido se desprenden tres compromisos que orientarán los capítulos siguientes: justificar lo que se pretende conocer, contrastar las interpretaciones y evaluar las consecuencias de las decisiones. Estos compromisos permiten reconocer tanto las posibilidades de los datos como aquello que permanece fuera de sus representaciones. El siguiente capítulo abordará la predicción educativa desde esta base y examinará cómo una estimación puede convertirse en una oportunidad de acompañamiento, qué evidencia requiere esa transición y bajo qué condiciones resulta pertinente intervenir.

Capítulo 2
Nuevas competencias para el ejercicio profesional docente

Propósitos de la predicción: desempeño, dificultades académicas y abandono.

La predicción educativa busca estimar resultados todavía desconocidos a partir de información disponible sobre los estudiantes y sus contextos. Sus aplicaciones incluyen anticipar calificaciones, identificar posibles dificultades y estimar la probabilidad de interrupción de los estudios. Aunque estos propósitos comparten procedimientos analíticos, requieren definir resultados diferentes y organizar respuestas específicas. Romero y Ventura (2020) muestran la diversidad de tareas predictivas presentes en la minería de datos educativos y la analítica del aprendizaje. Esta diversidad exige precisar qué se pretende anticipar, en qué momento y para apoyar qué decisión.

La predicción del desempeño suele centrarse en resultados como la calificación final, la aprobación de una asignatura o el cumplimiento de un criterio académico. Estas estimaciones pueden contribuir a organizar apoyos durante el curso, siempre que se produzcan cuando todavía existe margen para actuar. Sin embargo, el resultado seleccionado delimita lo que el modelo permite conocer. Predecir una calificación representa un objetivo distinto de anticipar dificultades de comprensión o valorar la capacidad para aplicar conocimientos. La interpretación debe corresponder a la variable que efectivamente se estudió (Romero & Ventura, 2020).

Una investigación reciente realizada con datos de la Universidad Estatal de Milagro, en Ecuador, ilustra este propósito. Arévalo-Cordovilla y Peña (2025) analizaron información de 2.225 estudiantes de ingeniería en modalidad virtual, integrando registros de Moodle, antecedentes académicos y datos demográficos. Encontraron que las calificaciones de las primeras evaluaciones constituían predictores relevantes del desempeño posterior. El estudio también reconoció una limitación central: evaluó los modelos predictivos, pero no comprobó posteriormente su efectividad para orientar intervenciones educativas reales. Sus resultados respaldan posibilidades de anticipación en el contexto examinado, sin demostrar por sí mismos una mejora del aprendizaje o una reducción del abandono.

La identificación de dificultades académicas tiene un propósito más próximo al acompañamiento del proceso. Puede orientarse a reconocer señales que justifiquen examinar una situación: errores recurrentes, actividades incompletas o cambios en el desempeño. En educación secundaria, Sousa et al. (2021) identificaron aplicaciones de analítica relacionadas con la predicción de resultados y la detección de estudiantes que podrían necesitar apoyo. Su revisión muestra, además, que las experiencias estudiadas se concentraban en iniciativas de pequeña escala, una condición que debe considerarse antes de extender sus conclusiones a otros centros o poblaciones.

En este apartado, las dificultades académicas se entienden como problemas observables en la participación o realización de actividades, cuyo origen requiere investigación. Esta delimitación evita confundir una alerta educativa con un diagnóstico clínico o psicopedagógico. Por ejemplo, varias respuestas incorrectas pueden justificar una revisión docente, pero no permiten atribuir automáticamente una dificultad específica del aprendizaje. La respuesta inicial debería examinar el contenido, las instrucciones, los conocimientos previos y las condiciones de realización antes de formular conclusiones sobre la persona.

La predicción del abandono plantea un problema adicional: definir con precisión qué acontecimiento se considera abandono. Para diseñar un análisis, corresponde distinguir entre dejar una asignatura, interrumpir temporalmente los estudios, cambiar de programa o desvincularse de una institución. También debe establecerse el período de observación. Desde la propuesta metodológica de este libro, estas decisiones forman parte de la definición del resultado y deben declararse antes de interpretar las estimaciones. Una ausencia de matrícula en el período siguiente no permite, por sí sola, conocer toda la trayectoria posterior del estudiante.

La evidencia chilena muestra la importancia del momento en que se formula la predicción. Von Hippel y Hofflinger (2021) estudiaron el riesgo de abandono en ocho universidades y encontraron que la información disponible al ingreso tenía una capacidad predictiva limitada, mientras que la incorporación de calificaciones universitarias mejoraba la anticipación. Este resultado plantea una tensión práctica: esperar nuevas evidencias puede mejorar la identificación, pero reduce el tiempo disponible para organizar apoyos. La oportunidad de una alerta depende, por tanto, de su relación con el calendario académico y con la capacidad institucional de respuesta.

Tabla 4

Propósitos predictivos y decisiones educativas asociadas

Propósito	Resultado que se intenta anticipar	Decisión que podría apoyar	Precaución principal
Desempeño	Calificación, aprobación o cumplimiento de un criterio	Organizar refuerzo y seguimiento durante el curso	Una calificación no representa todas las dimensiones del aprendizaje
Dificultades académicas	Probabilidad de no alcanzar un objetivo o completar una actividad	Examinar necesidades y ajustar los apoyos	Una alerta no establece la causa ni equivale a un diagnóstico
Abandono	Interrupción definida para un programa, institución y período	Ofrecer orientación y acompañamiento pertinente	Deben distinguirse interrupción, traslado y desvinculación

Nota. Elaboración propia como síntesis conceptual a partir de Romero y Ventura (2020), Sousa et al. (2021) y von Hippel y Hofflinger (2021). Las decisiones propuestas son posibilidades de actuación, no intervenciones cuya efectividad haya sido demostrada por todas las fuentes citadas.

Estos propósitos pueden relacionarse, pero no deben utilizarse como equivalentes. Una probabilidad elevada de reprobación puede motivar apoyo académico, mientras que una posible interrupción podría requerir explorar condiciones económicas, organizativas o personales. La elección del resultado predictivo debe guardar relación con la necesidad institucional y con las acciones disponibles. Si el objetivo es organizar tutorías sobre contenidos, una estimación general de abandono puede ofrecer información insuficiente para decidir qué enseñar o cómo acompañar.

También conviene distinguir entre el riesgo de un resultado y la posibilidad de beneficiarse de una intervención. Identificar a quienes probablemente reprobarán no determina qué estrategia les resultará útil. Esta diferencia se observa en el estudio ecuatoriano de Arévalo-Cordovilla y Peña (2025), que reconoce la evaluación de intervenciones como una tarea pendiente. Para este

libro, la predicción constituye una primera evidencia para orientar la indagación; la selección del apoyo necesita una justificación pedagógica adicional y una valoración posterior de sus efectos.

La capacidad de respuesta debe considerarse desde el inicio. En un estudio con universidades chilenas y ecuatorianas, Hilliger et al. (2020) identificaron desafíos relacionados con los sistemas de información y las políticas de utilización de datos. Estos hallazgos permiten situar la predicción dentro de una organización concreta. Desde este planteamiento, una institución que incorpora alertas necesita definir quién las revisa, cómo se contrasta la información y qué apoyos puede ofrecer. Generar una lista de estudiantes clasificados por riesgo deja sin resolver estas decisiones.

El propósito educativo de la predicción queda delimitado cuando se articulan un resultado claramente definido, un momento oportuno y una respuesta posible. Su contribución debe examinarse según la calidad de las decisiones que ayuda a fundamentar y las oportunidades de acompañamiento que abre. Esta relación orientará el siguiente apartado, dedicado a la construcción de modelos predictivos: la selección de variables, el entrenamiento y la validación deberán responder a un problema educativo explícito y a las condiciones reales de su utilización.

Construcción de modelos predictivos: variables, entrenamiento y validación, explicados para el lector educativo.

Construir un modelo predictivo educativo implica transformar una pregunta sobre una trayectoria académica en un procedimiento que pueda evaluarse con datos. Este proceso comprende la definición del resultado, la selección de variables, la preparación de la información y la evaluación de las estimaciones. La elección del algoritmo forma parte de ese recorrido, pero su utilidad depende de la coherencia entre el problema educativo y las decisiones metodológicas. Romero y Ventura (2020) sitúan estas operaciones dentro de un ciclo de descubrimiento de conocimiento que incluye la interpretación de los resultados y su relación con los objetivos del análisis.

El primer paso consiste en definir qué se desea predecir y cuándo se realizará la estimación. Para ilustrarlo, puede plantearse un caso hipotético: identificar al finalizar la cuarta semana a estudiantes que podrían no aprobar una asignatura al terminar el semestre. Esta formulación establece el resultado de interés, el momento de predicción y el período durante el cual todavía sería posible ofrecer

apoyo. También delimita los datos admisibles: únicamente debería utilizarse información disponible hasta la cuarta semana. Sin esta precisión temporal, un modelo puede parecer útil para la detección temprana aunque dependa de evidencias que llegan demasiado tarde.

El resultado que se intenta anticipar se denomina variable objetivo. Puede expresarse como una cantidad, por ejemplo, una calificación, o como una categoría, como aprobación o reprobación. Las variables predictoras son las características utilizadas para estimarlo: evaluaciones previas, entregas, asistencia o registros de interacción. La selección debe atender a su disponibilidad, calidad y significado educativo. La revisión de Romero y Ventura (2020) muestra que diferentes tareas y entornos utilizan combinaciones diversas de información; por ello, incorporar más variables requiere justificar qué aportan y si podrán obtenerse en las condiciones reales de aplicación.

La evidencia latinoamericana permite observar esta relación. En ocho universidades chilenas, von Hippel y Hofflinger (2021) encontraron que la información disponible al ingreso tenía una capacidad limitada para anticipar el abandono, mientras que las calificaciones universitarias mejoraban la predicción. Este resultado muestra que la relevancia de una variable depende del momento en que se incorpora. Para la intervención, sin embargo, es necesario examinar cuánto tiempo queda disponible cuando esa información adquiere valor predictivo.

Una vez seleccionadas las fuentes, se prepara el conjunto de datos. Esta etapa incluye revisar duplicados, corregir inconsistencias, examinar ausencias y construir variables a partir de los registros. Por ejemplo, una secuencia de entregas puede resumirse mediante su frecuencia o distribución temporal. Tales transformaciones deben documentarse para que otra persona pueda comprender cómo se obtuvo cada medida. Además, cuando una operación aprende características del conjunto de datos —como los valores utilizados para completar información ausente—, debe ajustarse exclusivamente con los datos de entrenamiento y aplicarse después a los datos de evaluación. Utilizar información de estos últimos durante la preparación puede contaminar la evaluación (Kapoor & Narayanan, 2023).

El entrenamiento es el proceso mediante el cual un algoritmo ajusta sus parámetros para relacionar las variables predictoras con resultados conocidos. En términos educativos, utiliza ejemplos históricos para construir una regla de estimación que después se aplicará a nuevos casos. Pueden emplearse

procedimientos como regresión logística, árboles de decisión o métodos que combinan varios modelos. La comparación necesita incluir alternativas sencillas para establecer si una mayor complejidad aporta una mejora relevante.

El estudio de Arévalo-Cordovilla y Peña (2025), realizado con información de estudiantes de la Universidad Estatal de Milagro, ofrece un ejemplo de esta precaución. Los autores compararon distintos algoritmos y encontraron que un modelo combinado mediante *stacking* no superó a los mejores modelos individuales y presentó mayor inestabilidad. El hallazgo cuestiona la expectativa de que combinar más componentes produzca necesariamente mejores predicciones. Su alcance corresponde al conjunto de datos y al procedimiento evaluado, sin establecer una superioridad universal entre algoritmos.

Para juzgar un modelo, es necesario examinar su comportamiento en datos distintos de los utilizados para ajustarlo. Un procedimiento habitual distingue datos de entrenamiento, datos de validación para comparar alternativas o ajustar configuraciones y un conjunto de prueba reservado para la evaluación final. La separación busca reducir el riesgo de sobreajuste: que el modelo aprenda particularidades de los ejemplos históricos que no se mantienen en nuevos estudiantes. Si el conjunto de prueba se consulta repetidamente para modificar el modelo, deja de ofrecer una evaluación independiente (Kapoor & Narayanan, 2023).

La validación cruzada permite repetir la evaluación mediante varias particiones del conjunto de datos. En cada repetición, una parte se reserva para evaluar y las restantes se utilizan para entrenar. Sin embargo, las particiones deben corresponder al uso previsto. Si existen varios registros de un mismo estudiante y se desea estimar el desempeño en estudiantes nuevos, conviene mantener todos sus registros en una misma partición. Si se pretende aplicar el modelo a una cohorte futura, una evaluación temporal permite examinar mejor esa situación. Kapoor y Narayanan (2023) advierten que las dependencias entre datos y las separaciones inadecuadas pueden producir estimaciones excesivamente optimistas.

Un error especialmente relevante es la fuga de información. Ocurre cuando el proceso de desarrollo utiliza datos que no deberían estar disponibles para la predicción evaluada. En el ejemplo de la cuarta semana, incorporar la calificación final o el estado administrativo registrado después de terminar el curso permitiría anticipar el resultado mediante información del propio futuro. El sistema obtendría una aparente ventaja que desaparecería al utilizarlo

oportunamente. Este ejemplo hipotético muestra por qué debe comprobarse la fecha real de disponibilidad de cada variable, además de su relación estadística con el resultado.

La evaluación también necesita referencias de comparación. Considérese otro ejemplo hipotético: si el 90 % del alumnado aprueba, un sistema que clasifique a todas las personas como aprobadas alcanzaría un 90 % de aciertos, pero no identificaría a quienes podrían requerir apoyo. Por ello, el desempeño debe examinarse mediante varias medidas y según el propósito educativo. El siguiente apartado desarrollará esta interpretación con mayor detalle, incluyendo los errores y la incertidumbre.

Finalmente, la validación predictiva debe distinguirse de la evaluación de una intervención. Arévalo-Cordovilla y Peña (2025) reconocen que su investigación se concentró en desarrollar y evaluar modelos, sin comprobar posteriormente su efectividad para orientar apoyos reales. Esta distinción delimita dos preguntas: si el sistema anticipa adecuadamente un resultado y si utilizarlo mejora las decisiones educativas.

Desde este planteamiento, un modelo queda suficientemente descrito cuando permite conocer su objetivo, población, momento de aplicación, variables, preparación de datos y procedimiento de evaluación. Esa documentación ofrece una base para examinar sus resultados y valorar si puede transferirse a otras condiciones. La construcción técnica culmina así en una exigencia educativa: presentar estimaciones cuyo significado, límites y posibles usos puedan ser comprendidos por quienes deben decidir.

Interpretación de resultados: precisión, incertidumbre y consecuencias de los errores.

Interpretar un modelo predictivo requiere conocer qué resultado estima, cómo se evaluó y qué errores puede cometer. Expresiones como «alta precisión» ofrecen información insuficiente cuando no se especifica la medida utilizada. Un sistema puede acertar en la mayoría de los casos y, al mismo tiempo, identificar pocos estudiantes que posteriormente presentan dificultades. Saito y Rehmsmeier (2015) muestran la importancia de examinar medidas complementarias cuando las categorías tienen tamaños desiguales, una situación relevante para resultados educativos relativamente infrecuentes, como determinados tipos de abandono.

Para comprender estas diferencias, conviene comenzar con los resultados posibles de una clasificación. Si un sistema genera alertas sobre reprobación, puede señalar correctamente a quienes después reprueban, emitir alertas para quienes aprueban, omitir a quienes reprueban o reconocer correctamente a quienes aprueban. Estas combinaciones conforman una matriz de clasificación o matriz de confusión. Los términos «positivo» y «negativo» indican la presencia o ausencia del resultado definido como objetivo; no expresan una valoración sobre la persona.

Tabla 5

Ejemplo hipotético de clasificación del riesgo de reprobación en 100 estudiantes

Clasificación del sistema	Reprueban al finalizar	Aprueban al finalizar	Total
Genera una alerta	15: verdaderos positivos	15: falsos positivos	30
No genera una alerta	5: falsos negativos	65: verdaderos negativos	70
Total	20	80	100

Nota. Elaboración propia con datos ficticios para explicar las métricas. Se supone una evaluación del modelo sin intervenciones activadas por sus alertas, con el fin de evitar que una mejora posterior se interprete automáticamente como un error predictivo.

En este ejemplo, la exactitud global es del 80 %: el sistema clasifica correctamente a 15 estudiantes que reprueban y a 65 que aprueban. Sin embargo, predecir que todos aprobarán también alcanzaría un 80 % de exactitud, porque 80 de los 100 estudiantes efectivamente aprueban. La diferencia es que este segundo procedimiento no identificaría a ninguna persona que posteriormente reprueba. El ejemplo demuestra por qué la exactitud debe interpretarse junto con la distribución de los resultados y las consecuencias de cada clasificación.

La sensibilidad, también denominada exhaustividad o *recall*, expresa qué proporción de los casos que presentan el resultado fue identificada. En la tabla corresponde a 15 de los 20 estudiantes que reprueban: un 75 %. La precisión positiva o valor predictivo positivo responde a otra pregunta: de todas las alertas emitidas, ¿cuántas corresponden a estudiantes que finalmente reprueban? En este caso son 15 de 30, es decir, un 50 %. La especificidad indica qué proporción

de quienes aprueban fue clasificada sin alerta: 65 de 80, aproximadamente un 81 %. Estas medidas permiten examinar aspectos distintos del desempeño y evitan utilizar la palabra «precisión» de manera ambigua.

La puntuación F1 resume el equilibrio entre precisión positiva y sensibilidad mediante su media armónica. Para el ejemplo, su valor sería aproximadamente 0,60. Puede resultar útil para comparar modelos, pero no incorpora los verdaderos negativos ni expresa directamente las consecuencias educativas de los errores. Saito y Rehmsmeier (2015) destacan la utilidad de analizar conjuntamente precisión y sensibilidad, especialmente cuando el resultado de interés es poco frecuente. Aun así, elegir una medida resumen exige justificar qué dimensiones se consideran prioritarias.

Muchos sistemas producen primero una puntuación o probabilidad y después utilizan un umbral para decidir cuándo emitir una alerta. Por ejemplo, una institución podría señalar casos a partir de una probabilidad estimada del 30 %. Ese punto de corte constituye una decisión operativa que debe justificarse. Para un mismo modelo, reducirlo generalmente permite identificar más casos, pero también incrementa las alertas incorrectas. Elevarlo reduce la cantidad de alertas y puede dejar fuera a estudiantes que necesitan acompañamiento. Por ello, la selección del umbral debe relacionarse con el propósito del apoyo, sus posibles efectos y la capacidad institucional para revisar los casos.

El área bajo la curva ROC, conocida como AUC-ROC, evalúa la capacidad del modelo para ordenar los casos según su puntuación. En términos simplificados, representa la probabilidad de que un caso que presenta el resultado reciba una puntuación mayor que uno que no lo presenta, considerando los empates de manera convencional. Un AUC de 0,80 no significa que el sistema acierte en el 80 % de todas las clasificaciones ni que cada probabilidad individual sea fiable. La evaluación de la discriminación y la de las probabilidades estimadas responden a preguntas diferentes (Van Calster et al., 2019).

La calibración examina la correspondencia entre las probabilidades estimadas y la frecuencia observada del resultado. Si, en un conjunto suficientemente amplio de estudiantes con probabilidades cercanas al 30 %, aproximadamente tres de cada diez presentan el resultado, esa observación es compatible con una buena calibración en ese rango. Un modelo puede ordenar adecuadamente los casos y, sin embargo, sobreestimar o subestimar sus probabilidades. Van Calster et al. (2019) desarrollan esta distinción en el ámbito de la predicción clínica; aquí se

retoma su fundamento estadístico para el análisis educativo, sin trasladar sus resultados clínicos a las instituciones de enseñanza.

La incertidumbre también debe acompañar la comunicación de resultados. Las métricas se estiman a partir de muestras y pueden variar entre cohortes, asignaturas o instituciones. Además de presentar un valor promedio, resulta pertinente informar su variabilidad, los intervalos de confianza cuando correspondan y las condiciones de evaluación. En el estudio ecuatoriano de Arévalo-Cordovilla y Peña (2025), la comparación incluyó resultados de validación cruzada y mostró diferencias de estabilidad entre modelos. Esta información permite valorar si una aparente ventaja se mantiene entre particiones o depende de resultados variables.

Los errores adquieren significado educativo según las decisiones que desencadenan. Un falso negativo puede retrasar un apoyo, mientras que un falso positivo puede generar seguimiento innecesario, exposición de información o expectativas desfavorables. Su importancia depende del contexto: ofrecer voluntariamente una tutoría tiene implicaciones diferentes de restringir una matrícula. Baker y Hawn (2022) documentan que los algoritmos educativos pueden afectar de forma desigual a distintos grupos. Por ello, corresponde examinar la distribución de los errores y evitar que un promedio favorable oculte perjuicios concentrados en determinadas poblaciones.

La experiencia latinoamericana también muestra que la utilidad depende del momento de la estimación. Von Hippel y Hofflinger (2021), al estudiar universidades chilenas, encontraron mejoras predictivas al incorporar calificaciones universitarias, pero señalaron la tensión entre esperar información más útil y conservar tiempo para intervenir. Así, la valoración debe considerar conjuntamente capacidad de identificación, cantidad de alertas y oportunidad del acompañamiento.

Cuando una alerta activa un apoyo y el estudiante mejora, el resultado favorable no permite concluir automáticamente que la predicción inicial era incorrecta. La intervención puede haber modificado la trayectoria que se intentaba anticipar. Este problema exige distinguir la evaluación predictiva de la evaluación del efecto del acompañamiento. Desde la propuesta de este libro, las métricas deben utilizarse para fundamentar decisiones revisables y comunicar límites, manteniendo abierta la pregunta por los beneficios reales de actuar sobre las alertas. El siguiente apartado abordará precisamente cómo organizar sistemas de detección temprana vinculados con respuestas educativas concretas.

Sistemas de alerta temprana y organización del acompañamiento.

Los sistemas de alerta temprana articulan la identificación de posibles dificultades con procedimientos de revisión, contacto y seguimiento. Su funcionamiento comprende una infraestructura de datos, criterios para generar señales y una estructura institucional capaz de responder. La predicción adquiere utilidad cuando se incorpora a prácticas de acompañamiento con responsables y objetivos definidos. Herodotou et al. (2020) examinaron esta articulación mediante una intervención que combinó estimaciones de continuidad académica con actuaciones de los equipos de apoyo estudiantil de la Open University del Reino Unido. Su investigación permite estudiar la alerta como parte de un proceso de atención, cuya efectividad depende también de las acciones posteriores.

Conviene distinguir el modelo predictivo del sistema de alerta y del programa de acompañamiento. El modelo estima un resultado; el sistema organiza cuándo y a quién se comunica una señal; el programa establece las actuaciones educativas y los recursos disponibles. Esta delimitación funcional, adoptada en este capítulo, permite identificar responsabilidades y evaluar cada componente. Una estimación adecuada puede perder utilidad si llega fuera de plazo, carece de un destinatario responsable o no encuentra una respuesta institucional.

La oportunidad de la detección depende del calendario académico. La anticipación debe dejar margen para revisar la situación, acordar apoyos y observar cambios antes de que se consolide el resultado previsto. En universidades chilenas, von Hippel y Hofflinger (2021) encontraron que las calificaciones obtenidas durante los estudios mejoraban la predicción del abandono respecto de la información disponible al ingreso. El hallazgo plantea una tensión operativa: esperar datos más informativos puede aumentar la capacidad predictiva y, simultáneamente, reducir el período de actuación. La periodicidad de las alertas debe definirse según la disponibilidad efectiva de evidencias y los momentos en que todavía es posible intervenir.

La organización del acompañamiento requiere integrar las señales en procesos existentes de docencia, tutoría y orientación. La investigación latinoamericana aporta antecedentes sobre esta adaptación. Guerra et al. (2020) estudiaron la adecuación de un panel de asesoramiento académico en tres universidades de la región. El trabajo consideró cuatro componentes del contexto: objetivos, actores, momentos clave e interacciones. Los pilotajes mostraron resultados favorables en satisfacción, utilidad y apoyo a las tareas de asesoramiento y

decisión académica. Se trata de evidencia sobre adaptación y uso de una herramienta de orientación; sus resultados no equivalen a demostrar una reducción causal del abandono ni corresponden necesariamente a un sistema predictivo de alerta.

Este antecedente permite fundamentar una exigencia de diseño: la información debe corresponder a las decisiones del profesional que la recibe. El docente necesita interpretar dificultades relacionadas con las actividades de su asignatura; el tutor debe examinar la trayectoria y los acuerdos de seguimiento; las unidades de apoyo requieren información pertinente para sus competencias. Como propuesta organizativa de esta obra, cada alerta debería contar con una persona o unidad responsable, criterios de derivación y un registro de actuaciones. Esta distribución evita que la identificación se disuelva entre servicios o produzca contactos simultáneos sin coordinación.

La revisión del caso constituye una mediación necesaria entre la estimación y la actuación. El análisis debe comprobar la vigencia de la información, examinar las evidencias disponibles y recoger la perspectiva del estudiante. La probabilidad calculada puede orientar la atención, pero no establece por sí misma la causa de una dificultad ni determina qué apoyo resultará adecuado. Hilliger et al. (2020), en universidades chilenas y ecuatorianas, identificaron desafíos vinculados con la fiabilidad de los sistemas de información y las políticas de utilización de datos. Estos resultados respaldan la necesidad de revisar las condiciones institucionales antes de incorporar las alertas a decisiones de acompañamiento.

El contacto con el estudiante debe permitir precisar necesidades y acordar actuaciones. Desde el enfoque pedagógico desarrollado en el capítulo anterior, la comunicación ha de explicar el motivo del acercamiento, ofrecer información comprensible y facilitar una respuesta. Comunicar una categoría de riesgo sin aclarar su alcance puede convertir una estimación provisional en una atribución personal. Por ello, se propone centrar el intercambio en las dificultades identificadas, las alternativas disponibles y las decisiones que el estudiante puede tomar con apoyo institucional.

La evidencia experimental de Herodotou et al. (2020) muestra una aplicación documentada de esta vinculación entre detección y atención. En su estudio participaron 630 estudiantes de grado con baja probabilidad estimada de completar sus estudios, distribuidos aleatoriamente entre un grupo de control de 312 personas y uno de intervención de 318. Los equipos de apoyo utilizaron

actuaciones motivacionales mediante mensajes de texto, llamadas y correo electrónico. El grupo de intervención obtuvo resultados de retención significativamente mejores. El efecto corresponde al conjunto de actuaciones evaluado en esa institución y modalidad; no permite atribuir el beneficio exclusivamente al algoritmo ni a cada canal de comunicación por separado.

La capacidad de atención condiciona la viabilidad del sistema. La institución debe conocer cuántas alertas puede revisar, qué servicios están disponibles y qué continuidad puede ofrecer. Se propone que la priorización considere la urgencia, el tiempo restante para actuar, la necesidad expresada y los apoyos ya recibidos. Ordenar exclusivamente por una puntuación dejaría fuera información relevante para la decisión profesional. Tampoco debería suponerse que la ausencia de una alerta elimina la necesidad de atención: el acceso al acompañamiento debe conservar vías de solicitud directa y derivación docente.

La trazabilidad permite reconstruir el recorrido de cada señal y detectar interrupciones en la atención. El registro operativo debería diferenciar generación de la alerta, revisión, contacto, respuesta, derivación y seguimiento. Estas etapas permiten examinar si una dificultad reside en la identificación o en la ejecución del apoyo. También hacen posible distinguir una oferta de atención de una intervención efectivamente recibida. Esta propuesta debe acompañarse de criterios de acceso y confidencialidad, evitando acumular información personal que no resulte necesaria para el seguimiento.

La evaluación necesita abarcar funcionamiento, resultados y distribución de beneficios. Además del desempeño predictivo, corresponde examinar tiempos de respuesta, cobertura, participación y continuidad del acompañamiento. Baker y Hawn (2022) documentan que los algoritmos educativos pueden producir efectos desiguales entre grupos. En un sistema de alerta, esta preocupación debe extenderse a la respuesta institucional: identificar adecuadamente una necesidad no garantiza que todos los estudiantes puedan acceder al apoyo ofrecido. La evaluación debe considerar tanto los errores de detección como las barreras presentes durante la atención.

Un sistema de alerta temprana adquiere consistencia cuando integra detección oportuna, revisión contextual, comunicación y seguimiento verificable. Las experiencias examinadas muestran aportes distintos: la adaptación latinoamericana de herramientas de asesoramiento permite comprender su inserción en prácticas institucionales, mientras la investigación experimental de la Open University aporta evidencia sobre una intervención concreta. Mantener

esta distinción ayuda a valorar qué se ha comprobado y qué requiere investigación adicional. El apartado siguiente profundizará en ese problema: cómo pasar de anticipar un resultado a modificar su trayectoria mediante intervenciones pedagógicamente justificadas.

De la predicción a la intervención: diferencias entre anticipar un resultado y modificarlo.

La predicción y la intervención responden a problemas distintos. La primera estima la probabilidad de un resultado a partir de información disponible; la segunda introduce una actuación destinada a modificar una trayectoria. Un modelo puede identificar estudiantes con mayor probabilidad de reprobación sin establecer qué apoyo les permitirá superar sus dificultades. Esta separación constituye un problema central para la investigación aplicada: comprobar la capacidad predictiva de una herramienta no demuestra la efectividad de las decisiones adoptadas a partir de ella. Larrabee Sønderlund et al. (2019) examinaron esta brecha mediante una revisión sistemática de intervenciones basadas en analítica del aprendizaje y señalaron la necesidad de fortalecer su evaluación.

El tránsito hacia la intervención requiere formular una explicación sobre el cambio esperado. La identificación de un patrón debe relacionarse con una necesidad educativa susceptible de atención, una actuación fundamentada y un resultado evaluable. Esta relación puede organizarse mediante una teoría del cambio que explicite cómo se espera que el apoyo contribuya al aprendizaje o a la continuidad académica. Como criterio metodológico de esta obra, dicha formulación debería especificar destinatarios, contenidos, responsables, intensidad, duración y condiciones de acceso. Estas precisiones permiten examinar qué se aplicó y distinguir una propuesta pedagógica de una recomendación genérica.

La selección de predictores tampoco determina directamente los componentes de una intervención. Una variable puede contribuir a estimar un resultado sin constituir una causa modificable. Del mismo modo, alterar un indicador no garantiza transformar el proceso que pretende representar. La relevancia predictiva de una característica debe distinguirse, por tanto, de su utilidad para orientar acciones. En el estudio ecuatoriano de Arévalo-Cordovilla y Peña (2025), las primeras calificaciones aportaron información importante para anticipar el desempeño posterior. Los autores reconocieron que su investigación no evaluó la efectividad de las intervenciones educativas derivadas del modelo. Su

contribución corresponde al desarrollo predictivo; la elección y comprobación del apoyo permanecen como tareas adicionales.

La atribución de efectos exige considerar qué habría ocurrido sin la actuación evaluada. Este resultado alternativo, denominado contrafactual, no puede observarse simultáneamente en la misma persona bajo las mismas condiciones. Los diseños de evaluación procuran aproximarse a él mediante grupos o períodos de comparación. Una mejora posterior a la intervención resulta insuficiente para establecer causalidad, pues puede coincidir con cambios en la enseñanza, diferencias entre cohortes o variaciones en la dificultad de las evaluaciones. La revisión de Larrabee Sønderlund et al. (2019) identificó solamente 11 estudios que evaluaban la efectividad de intervenciones dentro de los 689 trabajos inicialmente localizados y calificó la calidad general de esa evidencia como moderada. Este resultado corresponde al período y los criterios de su revisión, no a un inventario actualizado de toda la investigación disponible.

La asignación aleatoria permite construir una comparación con mayor protección frente a diferencias iniciales entre participantes. Herodotou et al. (2020) utilizaron este diseño para evaluar actuaciones motivacionales dirigidas a estudiantes identificados mediante un modelo predictivo en la Open University. Encontraron mejores resultados de retención en el grupo de intervención. La interpretación debe circunscribirse al conjunto de actuaciones y a la población estudiada: el diseño respalda una comparación entre las condiciones evaluadas, pero no separa automáticamente la contribución de cada componente del acompañamiento. Tampoco demuestra que el mismo efecto se mantenga al trasladarlo a otras modalidades o instituciones.

Cuando la aleatorización no resulta viable, pueden emplearse diseños cuasiexperimentales u observacionales, siempre que se expliciten sus supuestos y limitaciones. La comparación entre quienes aceptan un apoyo y quienes lo rechazan requiere particular cautela: ambos grupos pueden diferir previamente en motivación, disponibilidad o necesidades. Ajustar estadísticamente algunas características no elimina necesariamente las diferencias no observadas. Desde el planteamiento metodológico del capítulo, la evaluación debe justificar la selección del grupo de comparación y precisar qué explicaciones alternativas permanecen abiertas.

La retroalimentación personalizada constituye una línea de intervención documentada. Pardo et al. (2019) estudiaron el uso de analítica para ampliar la provisión de comentarios individualizados en una asignatura de sistemas

computacionales de primer año de ingeniería. El trabajo abarcó tres años consecutivos y encontró una asociación favorable con la percepción de calidad de la retroalimentación y el rendimiento académico. Su aporte muestra cómo las trazas digitales pueden integrarse en una actuación pedagógica concreta. Al tratarse de un estudio de caso desarrollado entre cohortes, sus resultados deben distinguirse de la evidencia obtenida mediante asignación aleatoria.

Las experiencias latinoamericanas aportan otra dimensión: la adaptación de las herramientas a las prácticas de asesoramiento. Guerra et al. (2020) evaluaron paneles de orientación académica en tres universidades de la región y documentaron su utilidad para apoyar tareas y decisiones. Esta evidencia permite valorar aceptación, pertinencia e incorporación al trabajo institucional. Tales resultados son relevantes para la implementación, aunque no equivalen a una estimación causal del efecto sobre aprobación o permanencia. Mantener diferenciadas estas contribuciones evita exigir a un estudio respuestas que su diseño no permite ofrecer.

La evaluación de implementación permite comprender por qué una actuación produce resultados variables. Debe examinarse si el apoyo se ofreció en el momento previsto, si llegó a sus destinatarios, qué participación obtuvo y qué modificaciones experimentó durante su ejecución. La ausencia de mejora puede responder a una propuesta pedagógica inadecuada, pero también a una cobertura insuficiente o a una aplicación incompleta. Se propone, por ello, registrar por separado la asignación, la oferta, la recepción y la continuidad de la intervención. Esta distinción permite interpretar con mayor precisión los resultados y revisar los procedimientos.

También corresponde separar los indicadores de ejecución de los resultados educativos. La apertura de mensajes, la asistencia a tutorías y la consulta de recursos informan sobre el alcance del programa; la comprensión, el desempeño y la continuidad académica requieren evidencias específicas. El estudio de Pardo et al. (2019) resulta pertinente porque examinó tanto la percepción de la retroalimentación como el rendimiento. La elección de resultados debe responder al propósito declarado y contemplar un período de seguimiento suficiente, evitando atribuir una mejora formativa únicamente al aumento de actividad registrada.

La valoración de efectos debe incorporar su magnitud, incertidumbre y relevancia institucional. Una diferencia estadísticamente significativa necesita interpretarse junto con el tamaño del beneficio, los recursos utilizados y las

condiciones necesarias para sostenerlo. La retención, además, debe examinarse en relación con el progreso académico y las decisiones informadas del estudiante. Como orientación de esta obra, el acompañamiento debe ampliar alternativas y atender necesidades, conservando la posibilidad de revisar una trayectoria sin convertir la permanencia en el único criterio de éxito.

Pasar de la predicción a la intervención exige, en consecuencia, justificar tres relaciones: entre la señal y la necesidad educativa, entre la necesidad y el apoyo seleccionado, y entre la actuación realizada y el resultado observado. La calidad del modelo contribuye a la primera relación, mientras que las restantes requieren fundamentos pedagógicos y diseños de evaluación propios. Esta distinción ofrece la base para el apartado siguiente, dedicado a examinar la evidencia de efectividad y las condiciones de transferencia entre niveles e instituciones educativas.

Evidencia de efectividad y transferencia entre niveles e instituciones educativas.

La evidencia sobre analítica predictiva comprende resultados de distinta naturaleza: capacidad para anticipar acontecimientos académicos, utilidad para las decisiones profesionales y efectos de las intervenciones sobre los estudiantes. Estas contribuciones requieren criterios de valoración específicos. Un modelo puede discriminar adecuadamente entre resultados sin que se haya comprobado el beneficio de utilizarlo; una herramienta puede facilitar el asesoramiento sin producir cambios demostrados en la permanencia. La revisión sistemática de Larrabee Sønderlund et al. (2019) identificó esta distancia entre desarrollo analítico y evaluación de intervenciones, y señaló limitaciones metodológicas en la evidencia examinada.

Las síntesis recientes aportan resultados favorables, aunque heterogéneos. Liu et al. (2025) analizaron 34 estudios empíricos y encontraron un efecto global moderado de las intervenciones basadas en analítica sobre los resultados de aprendizaje. Su trabajo también examinó variaciones según el ámbito disciplinar, la etapa educativa, el entorno y las características de la intervención. Estos hallazgos respaldan posibilidades de mejora en las condiciones estudiadas; no establecen una efectividad uniforme para cualquier herramienta o institución. Además, los autores identificaron indicios de sesgo de publicación en la dimensión de adquisición de conocimientos, una limitación relevante al interpretar los beneficios estimados.

La lectura de estas síntesis exige considerar qué intervenciones agrupan. La retroalimentación personalizada, los paneles de seguimiento y el acompañamiento activado por alertas pueden movilizar procesos pedagógicos diferentes. Por ello, el efecto promedio de una categoría amplia no determina cuánto beneficio producirá una aplicación concreta. Desde el criterio de esta obra, la valoración debe identificar la actuación evaluada, su comparación, la población participante y el resultado observado. Esta delimitación permite utilizar la evidencia sin atribuir a la tecnología beneficios que podrían depender del apoyo docente o de otros componentes del programa.

La transferencia de modelos plantea un problema adicional. Gašević et al. (2016) estudiaron nueve asignaturas universitarias en modalidad combinada y documentaron diferencias entre modelos específicos de curso y modelos generales. Sus resultados mostraron que las condiciones de enseñanza y las formas de utilizar el entorno virtual afectaban la capacidad predictiva. Una misma variable puede adquirir significados distintos según su relación con las actividades y la evaluación. En consecuencia, compartir una plataforma tecnológica no basta para justificar la aplicación del mismo modelo entre asignaturas.

También conviene separar la transferencia predictiva de la transferencia de una intervención. La primera exige comprobar si las estimaciones conservan un desempeño adecuado en otra población o período. La segunda requiere examinar si el apoyo mantiene su pertinencia y efectividad bajo nuevas condiciones. Un modelo validado localmente puede activar una intervención insuficientemente fundamentada; una intervención respaldada por investigaciones puede aplicarse a destinatarios mal identificados. Como propuesta metodológica, ambos componentes deben evaluarse de forma articulada, conservando indicadores que permitan reconocer dónde se producen las dificultades.

El cambio de nivel educativo requiere especial cautela. Sousa et al. (2021), en una revisión centrada en educación secundaria, encontraron un predominio de iniciativas de pequeña escala y limitaciones en las evidencias sobre sus resultados educativos. Sus conclusiones corresponden al corpus y al período analizados, pero permiten cuestionar la extrapolación automática de experiencias universitarias al ámbito escolar. La organización curricular, la participación familiar, los servicios de orientación y las responsabilidades de protección del alumnado deben examinarse al adaptar una propuesta. La

equivalencia técnica de los datos no garantiza equivalencia pedagógica entre niveles.

En América Latina, la investigación sobre adaptación institucional aporta criterios para esta discusión. Guerra et al. (2020) documentaron la adecuación de un panel de asesoramiento académico en tres universidades, atendiendo a objetivos, actores, momentos clave e interacciones. Los pilotajes aportaron evidencia sobre satisfacción, utilidad y apoyo a las tareas de orientación. Su contribución muestra la importancia de ajustar la herramienta a prácticas concretas; no constituye una demostración causal de mejoras en aprobación o permanencia. Esta distinción permite reconocer el valor de los estudios de implementación sin confundirlo con evidencia de impacto.

Las condiciones organizativas también delimitan la transferibilidad. Hilliger et al. (2020), en universidades chilenas y ecuatorianas, identificaron dificultades relacionadas con los sistemas de información y las políticas de utilización de datos. La adopción necesita considerar, por tanto, la disponibilidad de registros fiables, las competencias profesionales y los recursos de acompañamiento. Incorporar un sistema desarrollado en otra institución exige revisar estas condiciones antes de atribuir sus resultados a la calidad del algoritmo o a la disposición de los usuarios.

A partir de estos antecedentes, se propone una adopción gradual que combine revisión de la evidencia, validación local y evaluación de implementación. La validación debe examinar resultados en cohortes o períodos distintos de los utilizados durante el desarrollo. La evaluación institucional debe comprobar cobertura, oportunidad, accesibilidad y continuidad del apoyo. Si las estimaciones o las actuaciones muestran resultados insuficientes, corresponde revisar el procedimiento antes de ampliar su alcance. El pilotaje adquiere valor cuando permite tomar decisiones sobre continuidad, modificación o retirada, con criterios establecidos de antemano.

La sostenibilidad requiere seguimiento después de la incorporación inicial. Los cambios curriculares, las modificaciones de la plataforma y las variaciones en la población pueden alterar el significado de las variables o las condiciones de atención. Se plantea, por ello, una revisión periódica del desempeño predictivo y de los resultados del acompañamiento. La permanencia del sistema debe justificarse mediante evidencias de utilidad educativa, evitando que su integración administrativa sustituya esa evaluación.

El recorrido del capítulo permite establecer que la predicción educativa comprende varias operaciones que deben conservar su distinción: definir un resultado, construir y validar un modelo, interpretar sus errores, organizar la atención y comprobar los efectos de intervenir. Cada operación aporta evidencias diferentes y presenta límites propios. La capacidad de anticipación constituye un recurso para orientar decisiones, cuyo valor depende del momento en que se utiliza y de la respuesta que permite ofrecer.

La conclusión que orienta esta obra es que una predicción debe abrir oportunidades de apoyo y permanecer sujeta a revisión. Su incorporación requiere tanto rigor metodológico como capacidad institucional para atender las necesidades identificadas. Con esta base, el tercer capítulo abordará la personalización del aprendizaje y la mediación docente: cómo traducir la información educativa en actividades, retroalimentación y apoyos diferenciados, preservando la participación del estudiante en las decisiones sobre su formación.

Capítulo 3
Personalización del aprendizaje y mediación docente

Personalización, diferenciación y adaptación: precisiones conceptuales

La personalización del aprendizaje comprende propuestas diversas para atender las características de los estudiantes y ajustar sus experiencias formativas. Su significado, sin embargo, cambia entre tradiciones pedagógicas e investigaciones. Bernacki et al. (2021), en una revisión sistemática de 376 estudios, identificaron una considerable variabilidad en las definiciones, los componentes de diseño y los resultados examinados. Esta diversidad obliga a precisar quién toma las decisiones, qué aspectos se modifican, qué información orienta los ajustes y qué finalidad educativa se persigue. La denominación «personalizado» ofrece información insuficiente si estas condiciones permanecen indefinidas.

La diferenciación de la enseñanza se refiere, en términos generales, a la organización deliberada de respuestas ante la diversidad del alumnado. Puede involucrar contenidos, actividades, tiempos, apoyos y formas de evaluación. Su fundamentación requiere reconocer diferencias relevantes para el aprendizaje y traducirlas en decisiones didácticas. Desde Argentina, Anijovich (2014) sitúa el trabajo en aulas heterogéneas en las prácticas cotidianas de enseñanza, la gestión institucional y las interacciones entre los actores escolares. Este enfoque permite comprender la diversidad como una condición que debe orientar el diseño educativo, con consecuencias concretas para la organización del aula.

La adaptación designa el ajuste de algún componente de la enseñanza en función de información sobre el estudiante y la situación. Puede afectar la dificultad de una tarea, la secuencia de contenidos, la retroalimentación o el grado de apoyo. Tetzlaff et al. (2021) proponen entender estos ajustes desde una perspectiva dinámica: las características relevantes cambian durante el aprendizaje y mediante la interacción con la enseñanza. Por ello, una adaptación pertinente necesita revisarse conforme aparecen nuevas evidencias. Mantener decisiones basadas exclusivamente en una evaluación inicial puede producir desajustes entre la experiencia ofrecida y las necesidades actuales.

Las relaciones entre estos términos no responden a una clasificación universal. Tetzlaff et al. (2021) utilizan personalización e individualización para referirse a ajustes dirigidos a una persona y distinguen la diferenciación como modificación

de la enseñanza para grupos. Otras aproximaciones atribuyen a la personalización una exigencia adicional: que el estudiante participe en las decisiones y encuentre sentido en lo que aprende. Coll (2017) desarrolla esta orientación dentro de las pedagogías centradas en el alumnado y los enfoques constructivistas. Las diferencias terminológicas expresan, por tanto, distintas maneras de concebir el papel del aprendiz y el alcance de la intervención docente.

Para mantener coherencia conceptual, esta obra empleará diferenciación para describir la diversificación planificada de la enseñanza ante necesidades diversas; adaptación para identificar ajustes específicos y revisables; y personalización para referirse a una orientación que articula esos ajustes con la participación del estudiante, sus propósitos y el significado de la experiencia. Esta delimitación constituye una decisión analítica del libro, no una definición consensuada por toda la literatura.

Tabla 6

Delimitación conceptual adoptada en esta obra

Concepto	Énfasis principal	Decisión pedagógica que permite examinar
Diferenciación	Diversificación de las oportunidades de enseñanza	Cómo se organizan actividades, apoyos y formas de participación ante necesidades diversas
Adaptación	Ajuste específico según evidencias disponibles	Qué componente se modifica, con qué fundamento y cuándo debe revisarse
Personalización	Articulación entre necesidades, participación y sentido del aprendizaje	Cómo interviene el estudiante en su trayectoria y cómo se relacionan los ajustes con sus propósitos formativos

Nota. Elaboración propia a partir de Anijovich (2014), Bernacki et al. (2021), Coll (2017) y Tetzlaff et al. (2021). Las categorías describen énfasis complementarios y pueden coexistir en una misma experiencia.

Esta delimitación permite examinar con mayor precisión las aplicaciones de inteligencia artificial. Un sistema que modifica automáticamente la secuencia de ejercicios realiza una adaptación; para valorar su contribución a la

personalización también debe analizarse qué decisiones conserva el estudiante y cómo comprende la trayectoria propuesta. La capacidad técnica de responder a diferencias individuales constituye un componente del diseño, cuyo alcance pedagógico depende de su relación con los objetivos y la participación. Bernacki et al. (2021) recomiendan fundamentar estos diseños en teoría y explicitar una relación entre sus componentes y los cambios esperados.

La mediación docente interviene en esa relación mediante la selección de metas, la interpretación de evidencias y la revisión de los apoyos. El conocimiento del contenido y de la actividad permite valorar si un ajuste facilita el progreso o restringe innecesariamente las oportunidades. Desde el enfoque de esta obra, atender las diferencias requiere conservar expectativas formativas justificadas y revisar las decisiones que limitan el acceso a contenidos más complejos. La clasificación inicial del desempeño debe servir para organizar apoyos temporales, evitando transformarse en una trayectoria difícil de modificar.

La perspectiva latinoamericana de las aulas heterogéneas aporta una consideración relevante: la atención a las diferencias compromete tanto la actividad individual como las relaciones y condiciones de enseñanza. Anijovich (2014) vincula el reconocimiento de la diversidad con la gestión y la interacción escolar. Retomando esta orientación, el capítulo abordará la personalización dentro de experiencias que pueden conservar objetivos compartidos, intercambio entre pares y construcción colectiva. El ajuste individual necesita examinarse junto con las oportunidades de participación en el grupo.

La evaluación debe corresponder al propósito de cada modificación. Diferenciar actividades exige comprobar su pertinencia para las necesidades identificadas; adaptar una secuencia requiere revisar si el ajuste favorece el progreso; personalizar una experiencia demanda examinar también participación y sentido. Estas dimensiones no pueden inferirse únicamente de la existencia de itinerarios distintos. La contribución educativa debe sustentarse en evidencias sobre lo que los estudiantes comprenden, realizan y deciden durante su formación.

Con estas precisiones, la personalización se abordará como una orientación pedagógica cuya realización depende de decisiones explícitas y revisables. La tecnología puede ampliar las posibilidades de ajuste, mientras docentes y estudiantes participan en la definición y valoración de la experiencia. El apartado siguiente examinará cómo los sistemas adaptativos, los tutores inteligentes y los

mecanismos de recomendación concretan esas funciones, atendiendo a sus fundamentos y límites.

Sistemas adaptativos, tutores inteligentes y recomendación de recursos.

Los sistemas adaptativos, los tutores inteligentes y los mecanismos de recomendación permiten ajustar componentes de la experiencia educativa mediante información sobre el estudiante y su actividad. Aunque pueden integrarse en una misma plataforma, cumplen funciones distintas: modificar la enseñanza, orientar la resolución de tareas o seleccionar recursos pertinentes. Su análisis requiere identificar qué necesidad atienden, qué evidencias utilizan y cómo se fundamentan sus decisiones. La literatura sobre tecnologías adaptativas y recomendación educativa muestra que estas funciones admiten configuraciones diversas, cuyo valor depende de su relación con los objetivos de aprendizaje (Aleven et al., 2017; Drachsler et al., 2015).

Un sistema adaptativo modifica aspectos de la instrucción a partir de información sobre las características del aprendiz y sus interacciones. La adaptación puede afectar la selección de actividades, su secuencia, la dificultad o los apoyos ofrecidos. Aleven et al. (2017) distinguen ajustes relacionados con dificultades comunes del contenido, diferencias entre estudiantes y respuestas durante la actividad. Esta perspectiva permite reconocer que la adaptación necesita considerar tanto el conocimiento del dominio como las evidencias individuales. Su pertinencia depende de qué se modifica, en respuesta a qué información y mediante qué criterio pedagógico.

El funcionamiento adaptativo suele apoyarse en un modelo del estudiante: una representación de características relevantes para orientar la enseñanza. Esta representación se actualiza mediante respuestas, actuaciones u otras medidas disponibles. Tetzlaff et al. (2021) subrayan que las características del aprendiz cambian durante el proceso y que las decisiones deben considerar esa dinámica. La adaptación exige, por tanto, revisar las estimaciones conforme se producen nuevas evidencias, evitando que una clasificación inicial determine de manera permanente el recorrido posterior.

Los sistemas de tutoría inteligente incorporan mecanismos para interpretar el trabajo del estudiante y proporcionar orientación durante la resolución de tareas. Su arquitectura suele distinguir conocimiento del dominio, representación del aprendiz, decisiones tutoriales e interfaz de interacción. Estas funciones permiten seleccionar problemas, identificar errores o proporcionar

ayudas en momentos específicos. El grado de detalle varía: algunos sistemas responden al resultado de una actividad y otros analizan pasos intermedios. La función tutorial debe valorarse según la correspondencia entre el apoyo proporcionado y el razonamiento que se pretende desarrollar (Ma et al., 2014).

La evidencia de efectividad requiere considerar el tratamiento de comparación. En su metaanálisis, Ma et al. (2014) encontraron beneficios de los tutores inteligentes frente a la enseñanza docente en grupos numerosos, determinados programas informáticos sin tutoría inteligente y el estudio individual con materiales. Las comparaciones con tutoría humana individual y enseñanza en grupos pequeños no mostraron diferencias estadísticamente significativas. Estos resultados respaldan determinadas aplicaciones evaluadas, pero no permiten afirmar equivalencia entre modalidades ni superioridad general sobre el trabajo docente. La interpretación depende de las condiciones y los comparadores incluidos.

La recomendación educativa se concentra en seleccionar y ordenar elementos que podrían resultar pertinentes para una persona o situación de aprendizaje. Puede dirigirse a recursos, actividades y otras oportunidades formativas. Drachsler et al. (2015), en una revisión de 82 sistemas de 35 países, documentaron la diversidad de aplicaciones de recomendación para apoyar el aprendizaje. La selección puede basarse en características del contenido, relaciones entre usuarios y recursos, o combinaciones de información. Cada procedimiento necesita vincular su criterio técnico de relevancia con una finalidad educativa explícita.

La valoración de un recomendador exige distinguir aceptación y aprendizaje. Que un recurso sea consultado o valorado favorablemente permite estudiar su recepción, pero todavía debe examinarse su contribución al objetivo formativo. La diversidad de propósitos y evaluaciones documentada por Drachsler et al. (2015) impide interpretar el éxito técnico como un resultado educativo uniforme. Desde esta perspectiva, el criterio de selección debe atender a la pertinencia curricular y a las necesidades identificadas, además de la probabilidad de que el estudiante utilice el material.

La relación entre estas tecnologías puede sintetizarse mediante sus funciones predominantes, reconociendo que sus límites son permeables (Aleven et al., 2017; Drachsler et al., 2015; Ma et al., 2014).

Tabla 7

Funciones de los sistemas adaptativos, tutores inteligentes y recomendadores educativos

Tecnología	Función predominante	Aspecto pedagógico que debe examinarse
Sistema adaptativo	Modificar componentes de la instrucción según evidencias del aprendizaje	Pertinencia de los ajustes y posibilidad de revisar la trayectoria
Tutor inteligente	Orientar la resolución mediante evaluación y ayudas	Correspondencia entre la asistencia y el razonamiento esperado
Recomendador educativo	Seleccionar y ordenar recursos o actividades	Relevancia para los objetivos y contribución al aprendizaje

Nota. Elaboración propia a partir de Aleven et al. (2017), Drachsler et al. (2015) y Ma et al. (2014). Las funciones pueden coexistir en una misma herramienta.

La mediación docente resulta necesaria para relacionar los ajustes con la secuencia didáctica y valorar el momento de ofrecer o retirar ayuda. Aleven et al. (2017) examinan la adaptación desde decisiones sobre contenido, características del aprendiz e interacción; Tetzlaff et al. (2021) destacan su actualización durante el proceso. De ambas aproximaciones se desprende que la pertinencia del apoyo debe revisarse conforme progresa el estudiante. En esta obra, ese criterio orientará el análisis de las posibilidades de supervisión docente y modificación de las recomendaciones.

Los aportes latinoamericanos sobre asesoramiento académico ofrecen antecedentes para estudiar esa supervisión. Guerra et al. (2020) documentaron la adaptación de un panel en tres universidades de la región, atendiendo a objetivos, actores, momentos e interacciones. Sus resultados corresponden al apoyo a decisiones de orientación y no prueban la efectividad de un tutor inteligente. Su relevancia para este apartado reside en mostrar que la incorporación de información analítica requiere ajustarse a las tareas y responsabilidades de quienes la utilizan.

El examen pedagógico de estas tecnologías debe especificar qué componente se adapta, quién puede revisar la decisión y qué resultado se espera mejorar. Bernacki et al. (2021) recomiendan fundamentar la personalización en una

conceptualización teórica explícita y evaluar la contribución de sus componentes. Este criterio permitirá abordar los sistemas adaptativos, tutoriales y de recomendación según la calidad de las oportunidades que ofrecen, manteniendo el vínculo entre información, intervención y evidencia. El siguiente apartado desarrollará la retroalimentación y los paneles de analítica como medios para interpretar y utilizar esa información.

Retroalimentación y paneles de analítica para docentes y estudiantes.

La información sobre el desempeño adquiere valor formativo cuando permite comprender lo realizado y orientar el trabajo posterior. Desde esta perspectiva, la retroalimentación constituye un proceso de interpretación y utilización de evidencias, en el que participan tanto quien ofrece una devolución como quien debe emplearla. Carless y Boud (2018) destacan que el estudiante necesita desarrollar capacidades para comprender la información recibida e incorporarla a sus estrategias. Anijovich y Cappelletti (2020), desde la tradición latinoamericana de evaluación formativa, sitúan este proceso dentro de condiciones de enseñanza que favorezcan comprensiones profundas y oportunidades de mejora.

La analítica puede contribuir a ese proceso mediante la organización de registros, la identificación de patrones y la elaboración de devoluciones diferenciadas. Pardo et al. (2019) estudiaron la provisión de retroalimentación personalizada mediante datos de actividad en una asignatura universitaria de ingeniería. Encontraron asociaciones favorables con la percepción de calidad de los comentarios y el rendimiento académico. Su trabajo muestra una aplicación en la que el procesamiento de datos se vincula con una actuación docente definida; el alcance del resultado corresponde al diseño y las condiciones de esa experiencia.

Los paneles de analítica "*learning analytics dashboards*", reúnen indicadores mediante representaciones visuales destinadas a facilitar su consulta e interpretación. Pueden mostrar resultados, evolución temporal o características de la participación, según sus objetivos y fuentes. Sin embargo, la visibilidad de una medida no determina su utilidad pedagógica. Paulsen y Lindsay (2024) identifican una transición hacia paneles fundamentados en teorías del aprendizaje y orientados a ofrecer posibilidades de reflexión y actuación. Su revisión también reconoce la persistencia de diseños centrados principalmente en comparar, informar y supervisar la actividad.

La distinción entre presentar información y ofrecer retroalimentación resulta decisiva. Un panel aporta evidencias que deben relacionarse con metas y criterios de valoración; la retroalimentación requiere que esas evidencias puedan utilizarse para mejorar el trabajo. Cuando las actividades se entregan únicamente al término de un curso o carecen de continuidad, disminuyen las oportunidades de aplicar los comentarios. Carless y Boud (2018) vinculan esta dificultad con el diseño curricular y proponen secuencias en las que el alumnado produzca, reciba y utilice información sobre su desempeño.

Para el docente, el panel debe facilitar la indagación sobre el aprendizaje y apoyar decisiones relacionadas con las actividades de enseñanza. Su pertinencia depende de la correspondencia entre indicadores, objetivos y acciones disponibles. La revisión de Matcha et al. (2020) encontró limitaciones en la fundamentación teórica y en la evaluación de paneles concebidos desde el aprendizaje autorregulado. Estos resultados advierten que seleccionar indicadores técnicamente disponibles exige una justificación adicional sobre los procesos que representan y las decisiones que pueden respaldar.

Para el estudiante, comprender el panel implica reconocer qué se mide, cómo se interpreta y qué posibilidades de actuación ofrece. La alfabetización en retroalimentación incluye disposiciones y capacidades para valorar información, formular juicios sobre el propio trabajo y utilizar las devoluciones recibidas. Carless y Boud (2018) atribuyen al profesorado una función de orientación mediante el diseño de actividades, el acompañamiento y la práctica de evaluación entre pares. Desde este enfoque, el acceso a los datos debe acompañarse de oportunidades para discutir su significado y relacionarlo con las tareas.

La elección de referencias comparativas también necesita fundamento. Paulsen y Lindsay (2024) encontraron que la comparación constituía una función frecuente en los paneles estudiados, mientras que las posibilidades de establecer metas y reflexionar aparecían con menor presencia. Esta distribución permite cuestionar qué interpretación favorece cada diseño: conocer la posición respecto del grupo puede aportar una referencia, pero no explica necesariamente qué estrategia debe revisarse. La selección de comparaciones debe responder al propósito formativo y permitir examinar el progreso en relación con criterios comprensibles.

La investigación latinoamericana aporta evidencia sobre el panel como soporte del asesoramiento. Guerra et al. (2020) analizaron la adaptación de una

herramienta en tres universidades de la región, con participación de investigadores de Chile y Ecuador. El proceso consideró objetivos, actores, momentos de utilización e interacciones, y los pilotajes documentaron utilidad para las tareas de orientación y decisión académica. Su contribución permite comprender la visualización como parte de una práctica profesional situada, cuya configuración debe ajustarse al diálogo y a las necesidades de sus usuarios.

La retroalimentación mediada por analítica conserva, además, una dimensión comunicativa. Anijovich y Cappelletti (2020) examinan condiciones y obstáculos para ofrecer devoluciones que promuevan comprensión. Aplicado a los paneles, este planteamiento exige atender a la claridad de los mensajes y a su relación con el contenido trabajado. Una medida necesita una explicación proporcional a la decisión que pretende orientar; la acumulación de gráficos o comentarios no garantiza que el destinatario pueda identificar qué revisar y cómo hacerlo. Esta última consideración constituye una implicación de diseño derivada de su enfoque formativo.

La evaluación debe comprobar cómo se interpreta y utiliza la información. La frecuencia de consulta permite conocer el uso del panel, mientras que los cambios en las estrategias, las revisiones de las producciones y los resultados académicos requieren evidencias diferentes. Matcha et al. (2020) y Paulsen y Lindsay (2024) coinciden en la necesidad de fortalecer la relación entre fundamentos pedagógicos, funciones del sistema y evaluación. Conviene distinguir, por tanto, satisfacción, facilidad de uso y contribución al aprendizaje, sin asumir que una valoración favorable demuestra por sí sola una mejora educativa.

La convergencia entre retroalimentación y analítica depende de una secuencia pedagógica reconocible: disponer de evidencias pertinentes, interpretarlas mediante criterios y utilizarlas en actuaciones posteriores. Los estudios revisados respaldan la necesidad de diseñar esa relación y examinar sus resultados, conservando la participación del docente y del estudiante (Carless & Boud, 2018; Pardo et al., 2019). Esta base permitirá abordar la inteligencia artificial generativa en el acompañamiento del aprendizaje y valorar sus respuestas según su exactitud, pertinencia y posibilidad de utilización formativa.

Inteligencia artificial generativa en el acompañamiento del aprendizaje

La inteligencia artificial generativa permite producir explicaciones, preguntas, comentarios y otros contenidos mediante interacciones en lenguaje natural. En educación, estas capacidades amplían las posibilidades de ofrecer asistencia durante el estudio y la elaboración de actividades. Su incorporación exige definir qué función cumple la herramienta, qué procesos debe realizar el estudiante y cómo se comprobará el aprendizaje. Miao y Holmes (2023) proponen evaluar estas aplicaciones desde una perspectiva centrada en las personas, con atención a la pertinencia pedagógica, la autonomía y la protección de los datos. La disponibilidad de respuestas inmediatas necesita, por tanto, una organización didáctica que justifique su utilización.

El acompañamiento generativo se desarrolla mediante intercambios en los que la respuesta puede modificarse según las preguntas, los intentos y la información aportada por el usuario. Esta flexibilidad permite configurar apoyos distintos, aunque el diálogo por sí mismo no garantiza una intervención tutorial adecuada. Bastani et al. (2025) muestran que herramientas construidas sobre un mismo modelo pueden producir efectos educativos diferentes cuando cambian las instrucciones que regulan su asistencia. La configuración pedagógica debe examinarse como un componente de la intervención, junto con el contenido y las condiciones de uso.

La distinción entre desempeño asistido y aprendizaje independiente resulta central para valorar estos sistemas. En un ensayo aleatorizado realizado en matemáticas de secundaria en Turquía, Bastani et al. (2025) compararon una interfaz de asistencia general, un tutor con restricciones diseñadas para proteger el aprendizaje y una condición sin IA generativa. El acceso a ambas herramientas mejoró la resolución durante la práctica. Al retirarse la asistencia, el grupo que había utilizado la interfaz general obtuvo un desempeño inferior al control; el tutor con restricciones mitigó ese perjuicio, pero no mostró una mejora significativa respecto del control en la evaluación sin ayuda. El estudio evidencia que resolver más ejercicios con asistencia y adquirir capacidades para resolverlos de manera autónoma son resultados diferentes.

La evidencia también documenta beneficios bajo diseños específicos. Kestin et al. (2025) evaluaron un tutor generativo en una asignatura universitaria de física mediante un ensayo aleatorizado. Encontraron mayores ganancias de aprendizaje que en la condición de enseñanza activa presencial examinada. La herramienta incorporaba principios pedagógicos y soluciones previamente

elaboradas para apoyar la exactitud del contenido. Estos resultados corresponden a una intervención delimitada y no demuestran que cualquier chatbot produzca el mismo efecto ni que la ventaja se mantenga a largo plazo. Los propios autores reconocen límites para generalizar sus hallazgos a otros contextos y tareas.

Ambas investigaciones sitúan el diseño de la asistencia en el centro del análisis. El acompañamiento puede organizarse para proporcionar pistas, solicitar intentos y sostener la actividad del estudiante, o facilitar el acceso directo a una solución. En Bastani et al. (2025), las restricciones basadas en aportes docentes modificaron la forma de utilizar el tutor; en Kestin et al. (2025), la intervención se estructuró alrededor de contenidos y principios de enseñanza definidos. La consecuencia pedagógica es examinar qué operaciones intelectuales conserva el estudiante y qué funciones asume el sistema, antes de atribuir beneficios a la interacción generativa en términos generales.

La mediación docente comprende la delimitación de objetivos, la selección de materiales y la revisión de las respuestas que se incorporan al trabajo académico. Miao y Holmes (2023) recomiendan que las instituciones examinen la adecuación pedagógica y ética de estas herramientas y desarrollen capacidades para su utilización crítica. Desde esta orientación, la tarea docente incluye establecer cuándo la asistencia contribuye al propósito formativo, qué productos deben verificarse y qué evidencias permitirán valorar el progreso. La flexibilidad de la herramienta necesita una relación explícita con el currículo y los criterios de evaluación.

La exactitud constituye una condición específica del acompañamiento. Los sistemas generativos pueden producir información incorrecta o referencias inexistentes con una formulación convincente; por ello, su respuesta requiere contraste con fuentes y criterios disciplinares. La guía de Miao y Holmes (2023) advierte sobre la necesidad de validar los resultados y preservar la responsabilidad humana. En el ensayo de Kestin et al. (2025), la utilización de soluciones previamente preparadas formó parte del diseño destinado a sostener la fiabilidad. Esta decisión muestra que la calidad del contenido debe trabajarse durante la construcción de la intervención y no darse por supuesta a partir de la fluidez lingüística.

La incorporación de IA generativa también puede transformar la evaluación si se distingue entre la calidad del producto asistido y las capacidades adquiridas. Los resultados de Bastani et al. (2025) respaldan la necesidad de incluir tareas

realizadas sin la herramienta cuando el objetivo sea comprobar desempeño independiente. Esa evaluación debe corresponder a las competencias declaradas y al tipo de asistencia permitido durante el aprendizaje. Cuando se pretende desarrollar el uso crítico de IA, además, resulta pertinente examinar cómo el estudiante verifica la información y fundamenta sus decisiones; esta última orientación deriva del enfoque de responsabilidad humana planteado por Miao y Holmes (2023).

En América Latina y el Caribe, la discusión requiere considerar la distancia entre adopción y preparación institucional. Valentini (2026) analizó una encuesta realizada a 200 instituciones de educación superior de 19 países y encontró una incorporación de IA más extendida en docencia y aprendizaje que en otras funciones, acompañada de menor desarrollo de estrategias, políticas y mecanismos formales de evaluación. El estudio examina IA en sentido amplio y describe las instituciones participantes; no permite atribuir esos resultados exclusivamente a la IA generativa ni establecer su efectividad pedagógica. Su aporte para este apartado consiste en documentar condiciones institucionales que deben atenderse al organizar el acompañamiento.

El contexto regional también presenta diferencias de acceso y capacidades profesionales. La Oficina para América Latina y el Caribe del IIPE UNESCO (2025) destaca la necesidad de integrar gobernanza, accesibilidad y formación docente en las políticas digitales. Aplicada al acompañamiento generativo, esta orientación exige examinar si el alumnado dispone de condiciones comparables de utilización y si las actividades dependen de prestaciones que no están disponibles para todos. La decisión institucional debe contemplar alternativas de apoyo y evitar que el acceso a una herramienta determine las oportunidades de participación.

La evidencia revisada permite sostener que el valor educativo de la IA generativa depende de cómo se organiza y evalúa su asistencia. Los ensayos de Bastani et al. (2025) y Kestin et al. (2025) muestran resultados distintos bajo configuraciones y condiciones diferentes; la orientación de Miao y Holmes (2023) sitúa esa evaluación dentro de responsabilidades pedagógicas e institucionales. El criterio que guiará este capítulo será comprobar si el acompañamiento contribuye a desarrollar comprensión y capacidad de actuación, además de mejorar la producción inmediata. Esta distinción conduce al siguiente apartado, dedicado a la autorregulación, la participación y la autonomía del estudiante.

Autorregulación, participación y autonomía del estudiante.

Una trayectoria puede ajustarse al desempeño de un estudiante y, aun así, dejarle escaso margen para decidir sobre su aprendizaje. La distinción es relevante para este capítulo: mientras la adaptación modifica aspectos de la enseñanza según la información disponible, la personalización también plantea quién puede intervenir en esas decisiones. Coll (2017) sitúa la participación del aprendiz en la definición de objetivos y en la orientación de su recorrido como un rasgo distintivo de la personalización. Desde este planteamiento, el valor de un apoyo tecnológico depende tanto de su pertinencia como de las posibilidades que ofrece al estudiante para comprenderlo, discutirlo y utilizarlo.

La autorregulación se refiere a los procesos mediante los cuales el estudiante orienta su actividad hacia una meta, supervisa su avance y modifica sus estrategias a partir de lo que observa. Incluye componentes cognitivos y metacognitivos, así como la regulación de la motivación, las emociones y la conducta. Panadero (2017) muestra que los modelos de autorregulación difieren en el énfasis que conceden a estas dimensiones y en cómo explican su desarrollo individual y compartido. Esta distinción tiene una consecuencia para el diseño de apoyos: ayudar a organizar el tiempo, favorecer la comprensión de una tarea y sostener el esfuerzo son propósitos diferentes. Cada uno requiere información y formas de acompañamiento acordes con el proceso que se busca desarrollar.

Los registros digitales pueden aportar evidencias sobre algunas de esas operaciones, siempre que se interpreten dentro de la actividad. En un estudio con participación de investigadores de Ecuador y Chile, Maldonado-Mahauad et al. (2018) combinaron el análisis de secuencias de interacción en tres cursos masivos abiertos en línea con autoinformes sobre estrategias de autorregulación. El interés del trabajo para este apartado reside en la relación entre ambas fuentes: la secuencia de acciones permite describir un patrón de actividad, mientras que la información aportada por el estudiante ayuda a examinar qué estrategia podría estar utilizando. La correspondencia entre ambas ofrece una hipótesis mejor fundamentada; los patrones identificados en esos cursos no constituyen una medida universal de la autorregulación.

La participación añade una dimensión que los registros de actividad captan solo en parte. Reeve y Tseng (2011) describen la participación agéntica como la contribución del estudiante a la configuración de la enseñanza que recibe. Formular preguntas, expresar necesidades o proponer modificaciones son formas de intervenir en el proceso, cuya relevancia depende de que exista una

posibilidad efectiva de respuesta. Aplicado a la personalización, este planteamiento permite distinguir entre responder dentro de una ruta ya definida y tener voz sobre el apoyo o el itinerario propuesto. Una interfaz que permite elegir entre varias opciones ofrece cierto margen de decisión; para valorar su alcance, corresponde examinar qué cambia con esa elección y si puede revisarse.

La autonomía, a su vez, concierne a la posibilidad de actuar con un sentido de voluntad y apropiación de las decisiones. Desde la teoría de la autodeterminación, el apoyo a la autonomía es compatible con la orientación docente, la estructura de la actividad y la ayuda de otras personas (Ryan & Deci, 2020). En términos didácticos, esto permite entender el acompañamiento como una condición que puede ampliar la capacidad de decidir. Explicitar los criterios de una tarea, discutir las razones de una recomendación y ofrecer alternativas viables son formas de sostener decisiones informadas. La cuestión pedagógica es cuánto control puede asumir el estudiante y qué apoyos necesita para ejercerlo de manera progresiva.

Esta relación adquiere importancia cuando los sistemas de analítica elaboran perfiles o recomiendan trayectorias. Prinsloo y Slade (2016) vinculan la agencia estudiantil con las asimetrías de poder que surgen cuando una institución recopila e interpreta datos sobre sus estudiantes. A partir de su análisis, se propone que el estudiante pueda conocer el propósito de una recomendación, aportar información que la contextualice y solicitar su revisión cuando tenga consecuencias para su recorrido. En el plano pedagógico, el docente necesita comprobar si el ajuste responde a una necesidad vigente y si mantiene abiertas las oportunidades de acceder a contenidos más complejos. El desempeño registrado puede justificar un apoyo temporal; restringir una trayectoria exige una justificación distinta y una vía efectiva de revisión (Coll, 2017; Prinsloo & Slade, 2016).

Evaluar estas dimensiones exige ajustar las evidencias a cada propósito. Como criterio para esta obra, la autorregulación puede examinarse mediante las metas formuladas, los cambios de estrategia y las razones que el estudiante ofrece para esos cambios. La participación requiere observar si sus aportes inciden en la actividad y cómo se incorporan al diálogo pedagógico. Para valorar la autonomía, interesa establecer qué decisiones pudo tomar, con qué información y con qué posibilidades de reconsiderarlas. Los accesos a un panel o el cumplimiento de recomendaciones aportan información sobre el uso del sistema; para interpretar su significado formativo conviene contrastarlos con

producciones, reflexiones y decisiones del estudiante (Maldonado-Mahauad et al., 2018; Panadero, 2017; Reeve & Tseng, 2011).

El criterio que se desprende de este apartado es que el apoyo personalizado debe aumentar la capacidad del estudiante para orientar su trabajo y participar en las decisiones que afectan su formación. Una experiencia puede mejorar el desempeño inmediato y dejar abierta la pregunta de si el alumnado comprende mejor la tarea, dispone de estrategias propias y conserva opciones para continuar aprendiendo. El apartado 3.6 retomará estas exigencias al examinar cómo diseñar y evaluar experiencias personalizadas considerando conjuntamente el aprendizaje, la inclusión y la carga de trabajo docente (Coll, 2017; Panadero, 2017; Ryan & Deci, 2020).

Diseño y evaluación de experiencias personalizadas: aprendizaje, inclusión y carga de trabajo docente.

Diseñar una experiencia personalizada comienza por identificar una necesidad de aprendizaje y decidir qué aspecto de la enseñanza conviene ajustar. La selección de una plataforma, un tutor o un sistema de recomendación viene después. Bernacki et al. (2021) encontraron que las propuestas de personalización suelen combinar varios componentes y que, cuando su fundamento pedagógico queda implícito, resulta difícil determinar qué produjo los cambios observados. Para que una propuesta pueda evaluarse, el diseño debe precisar qué se modifica, quién toma esa decisión, con qué evidencias se revisará y qué resultado justificaría mantener el ajuste.

La mediación docente cobra especial importancia al decidir qué puede variar y qué debe mantenerse como horizonte compartido. Diferenciar los tiempos, las formas de participación o los apoyos permite responder a la heterogeneidad del aula sin renunciar a objetivos comunes. Desde la perspectiva desarrollada por Anijovich (2014), atender a la diversidad implica revisar las actividades, las interacciones y la organización de la enseñanza. Coll (2017) añade la participación del estudiante en la definición de su recorrido. A partir de ambos planteamientos, este capítulo propone tratar los itinerarios como decisiones revisables: el estudiante debe poder comprender por qué recibe un apoyo, aportar información sobre su pertinencia y acceder a tareas más exigentes cuando su progreso lo permita.

La evaluación del aprendizaje debe distinguir el rendimiento durante la actividad asistida de la capacidad que el estudiante desarrolla. La revisión de Van Schoors

et al. (2021) identificó una tendencia favorable en los resultados de la personalización digital en educación primaria y secundaria, aunque la diversidad de diseños y medidas limita las comparaciones. El ensayo de Bastani et al. (2025), discutido en el apartado 3.4, muestra por qué importa esa distinción: el mejor desempeño durante la práctica con IA no se reprodujo necesariamente en la evaluación sin asistencia. Si el objetivo es desarrollar una competencia independiente, corresponde recoger evidencias en condiciones acordes con ese propósito. Si se busca aprender a trabajar con IA, la evaluación debe examinar la calidad de las verificaciones, los juicios y las decisiones del estudiante. La evidencia que se recoja debe responder a la competencia que se afirma haber desarrollado.

La inclusión se examina observando quién puede acceder a la experiencia, participar en ella y beneficiarse de sus apoyos. El acceso formal a una herramienta deja abiertas preguntas sobre conectividad, accesibilidad y posibilidades reales de utilizarla, especialmente cuando existen diferencias entre las prestaciones gratuitas y las de pago (Instituto Internacional de Planeamiento de la Educación de la UNESCO, 2025). También importa qué oportunidades ofrece el sistema una vez que el estudiante ingresa. Baker y Hawn (2022) documentan que los sesgos pueden aparecer en distintas etapas de los sistemas algorítmicos educativos. Una consecuencia para el diseño es revisar la distribución de los apoyos y el acceso a tareas de distinta complejidad: un promedio favorable puede ocultar que algunos grupos reciben menos oportunidades de avanzar o que sus dificultades quedan sin atender.

La experiencia latinoamericana muestra que la adecuación de una herramienta se construye en el trabajo institucional. Guerra et al. (2020) analizaron la adaptación de un panel de asesoramiento en tres universidades de la región, con participación de instituciones chilenas y ecuatorianas. Los pilotajes permitieron valorar su utilidad para la orientación y la toma de decisiones académicas. El alcance de esa evidencia es específico: informa sobre el uso de la herramienta y su ajuste a las prácticas de asesoramiento. Una evaluación posterior tendría que establecer si las decisiones apoyadas por el panel se tradujeron en mejores oportunidades de aprendizaje o permanencia. Esta distinción permite reconocer los logros de una implementación sin confundirlos con sus efectos educativos.

La carga de trabajo docente debe medirse sobre el proceso completo. La preparación de materiales es una parte del trabajo; también cuentan la revisión de las respuestas generadas, la interpretación de indicadores y el seguimiento

de los apoyos. En un ensayo sobre la preparación de clases de ciencias en secundaria, el grupo que utilizó ChatGPT con una guía dedicó un 31 % menos de tiempo a esa actividad que el grupo de comparación (Education Endowment Foundation, 2024). El resultado se refiere a una tarea delimitada y a una modalidad de uso que incluía orientación. Para valorar el ahorro en una experiencia de personalización, este capítulo propone registrar por separado el tiempo de puesta en marcha, el de preparación habitual y el dedicado a comprobar, corregir y dar seguimiento. Así puede establecerse si la herramienta libera tiempo para enseñar o si el ahorro en una fase queda absorbido por tareas posteriores.

Estas dimensiones deben examinarse en conjunto antes de ampliar una experiencia. A partir de Bernacki et al. (2021) y Guerra et al. (2020), se propone que el pilotaje documente el punto de partida, los ajustes introducidos, los apoyos efectivamente utilizados y los resultados obtenidos. Conviene contrastar las producciones del alumnado con su percepción de los apoyos y con el registro del trabajo docente. Si la experiencia mejora el rendimiento medio, pero deja fuera a parte del grupo o depende de una supervisión que la institución no puede sostener, hay razones para revisar el diseño antes de extenderlo. La decisión de mantenerlo debe apoyarse en evidencias sobre aprendizaje, participación y viabilidad.

La pregunta que abrió el capítulo —cómo adaptar la enseñanza sin restringir la autonomía ni las oportunidades del estudiante— encuentra aquí una respuesta pedagógica: ofrecer apoyos que puedan revisarse a medida que el estudiante progresa, conservar su participación en las decisiones y comprobar qué le permiten aprender. Los tutores, los paneles y la IA generativa cumplen funciones distintas dentro de ese trabajo. Corresponde al docente relacionarlas con los objetivos y al estudiante disponer de un margen efectivo para interpretar, discutir y utilizar la ayuda (Coll, 2017; Prinsloo & Slade, 2016). Esa distribución de responsabilidades abre la discusión del capítulo siguiente: quién puede utilizar los datos, quién responde por las decisiones que se toman a partir de ellos y cómo puede el estudiante cuestionar una clasificación que afecta sus oportunidades.

Capítulo 4
Dilemas éticos y gobernanza de los datos educativos

Privacidad, consentimiento y protección de datos: atención particular a menores de edad.

Los datos producidos durante la enseñanza pueden circular mucho después de que termine una actividad y llegar a personas que nunca participaron en ella. Una plataforma puede reunir entregas, calificaciones y registros de interacción para apoyar el seguimiento académico. El problema ético aparece cuando esa información se conserva, se combina o se reutiliza para fines que el estudiante difícilmente podía prever. La pregunta que abre este capítulo, qué condiciones hacen justificable el uso de estas tecnologías, exige examinar la finalidad de cada tratamiento, la necesidad de los datos y las posibilidades que tiene el estudiante de intervenir cuando su información se utiliza. En el caso de niñas, niños y adolescentes, la privacidad debe protegerse junto con el derecho a participar y a que sus opiniones sean consideradas de acuerdo con su edad y madurez (Comité de los Derechos del Niño, 2021).

En Ecuador, la Ley Orgánica de Protección de Datos Personales (LOPDP) distingue entre la base que legitima el tratamiento y los principios que rigen su ejecución. La institución debe determinar para qué necesita la información y qué base jurídica corresponde a esa finalidad. El artículo 7 contempla varias bases de legitimación. Cuando se recurre al consentimiento, el artículo 8 exige que sea libre, específico, informado e inequívoco, y permite revocarlo mediante un procedimiento sencillo. En educación, estas condiciones obligan a examinar el margen real de elección. Si una función analítica es opcional, la institución debe valorar si el estudiante puede rechazarla sin perder acceso a la enseñanza o a la evaluación. La dependencia de una plataforma para cursar una asignatura puede comprometer la libertad con la que se acepta un uso adicional de los datos (Ley Orgánica de Protección de Datos Personales [LOPDP], 2021, arts. 7–8).

La finalidad debe formularse con suficiente precisión para decidir qué se recoge y durante cuánto tiempo se conserva. El artículo 10 de la LOPDP establece, entre otros, los principios de finalidad, minimización, proporcionalidad y conservación. Aplicarlos a la analítica educativa implica distinguir los datos necesarios para prestar el servicio de aquellos que una herramienta puede recopilar por defecto. También exige examinar por separado los usos posteriores. La información recogida para orientar una tutoría y su eventual utilización para entrenar un

modelo comercial responden a finalidades diferentes. La institución debe valorar la compatibilidad y la legitimación del nuevo uso, así como informar de manera comprensible sobre el alcance del tratamiento (LOPDP, 2021, arts. 7–8, 10 y 12).

En el caso de menores de edad, la LOPDP incluye sus datos personales entre las categorías especiales y establece salvaguardas específicas. El artículo 21 contempla la autorización expresa del titular o de su representante legal, según corresponda, y prevé el tratamiento destinado a salvaguardar un interés público esencial bajo condiciones de legalidad, necesidad y proporcionalidad, con medidas específicas de protección. A partir de los 15 años, los adolescentes pueden otorgar su consentimiento explícito en calidad de titulares cuando se les especifiquen con claridad los fines del tratamiento. Esta disposición debe leerse junto con la protección reforzada que la ley reconoce frente a decisiones basadas total o parcialmente en valoraciones automatizadas. La autorización para tratar datos y la revisión de una decisión que afecta la trayectoria del estudiante plantean obligaciones distintas (LOPDP, 2021, arts. 20–21 y 25).

La información dirigida a las familias y al alumnado debe permitir comprender qué se recoge, quién puede consultarlo, para qué se utiliza y cómo ejercer los derechos correspondientes. En el ámbito escolar, es pertinente preparar explicaciones adecuadas a la edad, aun cuando la autorización deba otorgarla el representante legal. El Comité de los Derechos del Niño (2021) vincula la protección de la privacidad digital con la evolución de las capacidades y la participación de la niñez. Desde esa perspectiva, escuchar al estudiante permite conocer cómo experimenta el seguimiento y qué consecuencias tiene para su participación. En el ámbito institucional, la claridad de la información se comprueba por lo que sus destinatarios pueden entender y hacer con ella, además de por su disponibilidad formal (Comité de los Derechos del Niño, 2021, párrs. 18 y 67–78; LOPDP, 2021, arts. 12 y 24).

La protección debe incorporarse antes de que la herramienta empiece a tratar información estudiantil. En Ecuador, el artículo 42 exige una evaluación de impacto previa cuando se identifica la probabilidad de un alto riesgo para los derechos y libertades de las personas o cuando la autoridad la requiere. Entre los supuestos expresamente previstos se encuentran el tratamiento a gran escala de categorías especiales y la evaluación sistemática y exhaustiva basada en tratamiento automatizado cuando sustenta decisiones con efectos jurídicos. La evaluación permite documentar qué riesgos se han identificado, qué medidas se adoptarán y qué cambios necesita el diseño antes de su puesta en marcha (LOPDP, 2021, art. 42).

En la práctica educativa, estos criterios alcanzan también las herramientas de IA generativa. Las consultas pueden contener fragmentos de trabajos, observaciones docentes o información procedente de expedientes. Antes de incorporar esos materiales, corresponde verificar si el servicio conservará las entradas, quién podrá acceder a ellas y qué usos posteriores están previstos. Miao y Holmes (2023) sitúan la protección de los datos y la validación institucional de las herramientas entre las condiciones de su adopción educativa. Para el acompañamiento pedagógico, esto supone seleccionar la información estrictamente necesaria, limitar los accesos y definir plazos de conservación acordes con el propósito del apoyo (LOPDP, 2021, arts. 10 y 37).

La privacidad condiciona qué información puede reunir una institución y para qué puede utilizarla. Una vez delimitado ese tratamiento, queda por examinar qué inferencias se construyen con los datos y cómo se distribuyen sus consecuencias. Los registros escolares reflejan oportunidades desiguales de participación y acceso. Cuando un sistema los utiliza para clasificar estudiantes o asignar apoyos, esas diferencias pueden trasladarse a las decisiones educativas. El apartado 4.2 abordará cómo identificar ese riesgo y qué evidencia permite valorar si el sistema reproduce o agrava desigualdades (Baker & Hawn, 2022).

Sesgos algorítmicos, discriminación y desigualdad educativa.

Una alerta temprana distribuye la atención de una institución. Puede hacer que algunos estudiantes reciban una tutoría a tiempo y que otros, con necesidades semejantes, queden fuera del seguimiento. Por eso, la evaluación de un modelo educativo debe examinar a quién identifica, a quién omite y qué ocurre después de la clasificación. Baker y Hawn (2022) muestran que los sesgos pueden originarse en distintas etapas del desarrollo y uso de un sistema, desde la selección de los datos hasta la interpretación de sus resultados. El rendimiento promedio describe solo una parte del problema.

En este apartado, el sesgo algorítmico se examina como un problema de medición, predicción o asignación que puede afectar de manera desigual a distintos grupos. Una disparidad estadística ofrece un punto de partida para investigar la discriminación. Para valorar esta última también es preciso conocer el criterio de decisión, la justificación del trato y sus consecuencias. La desigualdad educativa abarca diferencias previas en las oportunidades de acceso, participación y aprendizaje. Un sistema puede recoger esas diferencias en sus datos y reforzarlas si las convierte en criterios para distribuir apoyos o

restringir oportunidades. Analizar el sesgo exige, por tanto, seguir el recorrido desde el dato hasta la decisión (Baker & Hawn, 2022).

Parte del problema se origina al definir qué se pretende medir. Las calificaciones, los registros de actividad y las decisiones administrativas reflejan tanto el desempeño observado como las condiciones en las que se produjo. Cuando se utilizan como indicadores de capacidad o compromiso, la interpretación requiere evidencias adicionales. También conviene revisar las variables sustitutivas: excluir un atributo sensible del entrenamiento puede dejar intacta parte de la información asociada a él en otras variables. En el estudio uruguayo de Queiroga et al. (2022), la zona de la escuela durante el primer año de primaria figuró entre las variables más informativas de uno de los modelos. Su relevancia predictiva permite examinar cómo se incorpora el contexto territorial a la estimación, pero se necesita otro tipo de evidencia para atribuirle un efecto causal o justificar su uso en una decisión educativa (Baker & Hawn, 2022; Queiroga et al., 2022).

La experiencia uruguaya muestra cómo una auditoría puede modificar una decisión de adopción. Queiroga et al. (2022) utilizaron registros de 258.440 estudiantes para desarrollar ocho modelos orientados a identificar riesgo académico en secundaria. El análisis consideró el género, la zona escolar y la participación en programas de bienestar social. Uno de los modelos para la enseñanza técnica quedó excluido después de que el equipo detectara un sesgo que no logró corregir. El alcance de la auditoría corresponde a los atributos y criterios examinados. La pregunta por el efecto de las alertas sobre el abandono requiere, además, evaluar las intervenciones que se realicen a partir de ellas.

En Ecuador, Arévalo-Cordovilla y Peña (2025) evaluaron modelos de predicción del desempeño con datos de 2.225 estudiantes de ingeniería en modalidad virtual de la Universidad Estatal de Milagro. El estudio incorporó medidas de equidad relacionadas con el género, la etnia y la situación socioeconómica. Su aporte consiste en incorporar el examen de las disparidades a la evaluación técnica del modelo. Dado que la investigación se circunscribió a un programa de una sola institución, sus resultados deben interpretarse en ese contexto. Queda por comprobar cómo se distribuirían los beneficios y las cargas de una intervención real basada en esas predicciones.

Las métricas de equidad deben seleccionarse en función de la decisión que apoyará el sistema. En la asignación de tutorías, comparar la tasa de falsos negativos entre grupos permite examinar si determinados estudiantes con

dificultades quedan fuera del seguimiento con mayor frecuencia. La tasa de falsos positivos ayuda a identificar quiénes soportan contactos innecesarios o quedan expuestos a clasificaciones incorrectas. También interesa conocer cuántas personas reciben efectivamente el apoyo después de la alerta. Dos grupos pueden presentar tasas de detección semejantes y encontrar barreras distintas para acceder a la tutoría. Por ello, una auditoría educativa debe seguir tanto la distribución de los errores como la de los apoyos que el sistema contribuye a asignar (Baker & Hawn, 2022; Queiroga et al., 2022).

Para esta obra, el criterio de revisión será vincular cada disparidad observada con las decisiones que podrían producirla o agravarla. Esto implica examinar la cobertura de los datos, la definición del resultado, el umbral de alerta y las condiciones de acceso al acompañamiento. Los resultados por grupo deben leerse junto con el tamaño de las muestras y la incertidumbre de las estimaciones. Cuando la información sea insuficiente, la institución debe explicitar qué desigualdades todavía no ha podido evaluar. Esta exigencia lleva al apartado 4.3. Para que una disparidad pueda investigarse y corregirse, quienes resultan afectados necesitan conocer cómo se tomó la decisión, aportar información que el sistema pasó por alto y disponer de una vía efectiva para cuestionarla (Baker & Hawn, 2022; Prinsloo & Slade, 2016).

4.3. Transparencia, explicabilidad y posibilidad de cuestionar decisiones.

Cuando una institución utiliza un sistema de analítica para orientar el acompañamiento o la evaluación, el estudiante necesita saber qué papel tuvo el sistema en la decisión que le afecta. La transparencia permite conocer de antemano qué información se usa y con qué propósito. La explicabilidad ayuda a comprender cómo se obtuvo un resultado y cómo se interpretó en un caso concreto. La posibilidad de cuestionar la decisión permite aportar información, señalar errores y pedir que se revise. Estas tres garantías se complementan porque el acceso a la información solo adquiere valor práctico cuando la persona puede utilizarla para intervenir en el proceso (Ley Orgánica de Protección de Datos Personales [LOPDP], 2021, arts. 12 y 20; Miller, 2019; Prinsloo & Slade, 2016).

En Ecuador, el artículo 12 de la LOPDP reconoce el derecho a conocer, entre otros elementos, la finalidad y la base legal del tratamiento, el origen de los datos cuando proceden de otras fuentes, el plazo de conservación y la existencia de valoraciones o decisiones automatizadas, incluida la elaboración de perfiles. También comprende información sobre cómo ejercer los derechos y dónde

presentar reclamos. En educación, una aplicación de este principio consiste en explicar qué decisiones puede orientar la herramienta y quién interviene en ellas. La información debe estar disponible en un lenguaje que el alumnado pueda comprender y, cuando corresponda, adecuarse a la edad de niñas, niños y adolescentes (Comité de los Derechos del Niño, 2021; LOPDP, 2021, art. 12).

Tabla 8

Garantías y evidencias que permiten comprobarlas

Garantía	Pregunta del estudiante	Evidencia que la institución puede aportar
Transparencia	¿Qué datos utilizan y para qué?	Aviso comprensible que identifica las fuentes, la finalidad, el responsable y el uso previsto de las valoraciones automatizadas.
Explicabilidad	¿Qué influyó en el resultado y qué papel tuvo en la decisión?	Explicación del caso que distingue los datos utilizados, la estimación del sistema y el criterio aplicado por quien decidió.
Posibilidad de cuestionar	¿Cómo puedo corregir un dato o pedir que se revise la decisión?	Canal accesible para presentar observaciones y recibir una respuesta motivada de la instancia que puede revisar el caso.

Nota. Elaboración propia a partir de la LOPDP (2021, arts. 12, 14 y 20), Miller (2019) y Prinsloo y Slade (2016). La tabla sintetiza criterios de aplicación educativa. El alcance jurídico de cada derecho se determina según el tratamiento y la decisión examinados.

Una explicación individual debe distinguir dos cuestiones. La primera es qué información influyó en la estimación del sistema. La segunda es por qué la institución consideró pertinente actuar a partir de ella. La importancia estadística de una variable puede explicar parte del comportamiento del modelo, mientras que la decisión educativa requiere razones vinculadas con el propósito del apoyo, los criterios aplicables y las circunstancias del estudiante. Miller (2019) muestra que las explicaciones suelen ser selectivas y que su pertinencia depende de la pregunta de quien las recibe. Esto permite adaptar el nivel de detalle al destinatario y conservar, para la revisión técnica, la documentación necesaria para reconstruir el resultado (LOPDP, 2021, art. 20; Miller, 2019).

La investigación latinoamericana ofrece antecedentes para incorporar esa explicación al diálogo educativo. Guerra et al. (2020) documentaron la adaptación de un panel de asesoramiento académico en tres universidades de la región, con participación de instituciones de Chile y Ecuador. Las adaptaciones respondieron a diferencias en los objetivos, los usuarios, los momentos de consulta y las interacciones propias del asesoramiento. Los pilotajes aportaron evidencia sobre la utilidad del panel para las tareas de orientación. Para este apartado, el hallazgo respalda una decisión de diseño concreta: integrar la visualización en la conversación entre el estudiante y el profesional que puede interpretar los datos y atender sus observaciones. La efectividad de un procedimiento de impugnación tendría que evaluarse por separado (Guerra et al., 2020; Prinsloo & Slade, 2016).

El artículo 20 de la LOPDP reconoce el derecho a no quedar sujeto a decisiones basadas total o parcialmente en valoraciones automatizadas, incluida la elaboración de perfiles, cuando produzcan efectos jurídicos o afecten derechos y libertades fundamentales en los términos previstos por la ley. Entre las facultades que establece figuran solicitar una explicación motivada, presentar observaciones, conocer los criterios de valoración y los tipos y fuentes de datos utilizados, e impugnar la decisión. El propio artículo contempla excepciones, y el artículo 21 establece salvaguardas adicionales respecto de niñas, niños y adolescentes. Para determinar el alcance de estas disposiciones en una institución educativa, debe examinarse la incidencia efectiva de la valoración automatizada en la decisión y sus consecuencias para el estudiante (LOPDP, 2021, arts. 20–21).

En la práctica institucional, corregir un registro y cuestionar una decisión son actuaciones que pueden requerir respuestas distintas. La primera se refiere a la exactitud de la información. La segunda puede plantear que los criterios se aplicaron de forma inadecuada, incluso si los datos son correctos. Para esta obra, una revisión efectiva requiere que la instancia responsable pueda consultar la información utilizada, considerar las observaciones del estudiante y modificar la decisión cuando corresponda. La oportunidad de la respuesta también importa. Una revisión que llega después de que se cierra la posibilidad de acceder a un apoyo pierde parte de su valor educativo (LOPDP, 2021, arts. 14 y 20; Prinsloo & Slade, 2016).

La revisión de decisiones individuales puede revelar problemas en el funcionamiento general del sistema. Si se cuestionan reiteradamente las mismas fuentes de datos o los mismos criterios de clasificación, la institución dispone de

información para examinar cómo se construyen y utilizan los perfiles. El apartado 4.4 desplaza la atención hacia los efectos acumulados de esas prácticas. La frecuencia del seguimiento, la permanencia de las categorías y su circulación entre profesionales pueden influir en la manera en que una institución interpreta la trayectoria de un estudiante y en las oportunidades que le ofrece (Comité de los Derechos del Niño, 2021; Prinsloo & Slade, 2016).

Vigilancia, etiquetado y efectos sobre las trayectorias estudiantiles.

La distinción entre seguimiento pedagógico y vigilancia depende de qué se observa, durante cuánto tiempo y para qué se utiliza la información. Revisar las evidencias de una actividad para orientar la enseñanza tiene una finalidad delimitada. La observación continua de la conducta digital amplía el alcance del seguimiento, sobre todo cuando abarca espacios ajenos a la actividad escolar o cuando los registros quedan disponibles para decisiones posteriores. En el caso de niñas, niños y adolescentes, el Comité de los Derechos del Niño (2021, párrs. 67–78) advierte que la vigilancia digital debe ajustarse a la finalidad perseguida y respetar la privacidad del estudiante. En Ecuador, los principios de finalidad, minimización y proporcionalidad ofrecen criterios para examinar ese límite (Ley Orgánica de Protección de Datos Personales [LOPDP], 2021, art. 10).

La educación remota durante la pandemia documentó cómo el seguimiento puede extenderse fuera del aula. Human Rights Watch (2022) examinó productos de tecnología educativa avalados por gobiernos, incluidos los de Argentina, Brasil, Chile y Ecuador. Su análisis técnico identificó plataformas con mecanismos de rastreo capaces de seguir la actividad de los usuarios fuera del entorno educativo. El informe documenta las prácticas observadas en los productos y configuraciones examinados durante ese período. Para las instituciones, el hallazgo plantea una cuestión concreta de gobernanza: el alcance de la recolección debe comprobarse en el funcionamiento del servicio, además de examinarse en las condiciones que declara el proveedor (Human Rights Watch, 2022).

El etiquetado introduce un problema distinto. Una clasificación de riesgo resume una estimación sobre un resultado definido, en una población y un período determinados. El problema aparece cuando la categoría se incorpora al expediente o circula entre profesionales y empieza a utilizarse como una descripción estable del estudiante. Scholes (2016) examina las implicaciones éticas de aplicar a una persona conclusiones basadas en regularidades estadísticas de un grupo. En educación, la distinción importa porque la

estimación puede justificar una conversación o una oferta de apoyo, mientras que restringir una oportunidad exige valorar las circunstancias individuales y fundamentar la decisión por separado (Prinsloo & Slade, 2016; Scholes, 2016).

Las consecuencias de una etiqueta dependen de la actuación que desencadena. Una alerta puede facilitar el acceso a tutorías, pero también puede influir en las expectativas de quienes la reciben y en las opciones que consideran apropiadas para el estudiante. Si la categoría determina los apoyos, las tareas o los itinerarios que se le ofrecen, las decisiones institucionales pasan a formar parte de la trayectoria que el sistema volverá a observar. Este posible efecto de retroalimentación merece estudiarse: los resultados posteriores pueden reflejar tanto las condiciones iniciales como las oportunidades que se abrieron o se restringieron tras la clasificación. La literatura sobre sesgo y agencia estudiantil fundamenta este riesgo, cuya magnitud debe comprobarse en cada contexto (Baker & Hawn, 2022; Prinsloo & Slade, 2016).

La experiencia uruguaya permite precisar la diferencia entre auditar una clasificación y evaluar sus consecuencias. Queiroga et al. (2022) desarrollaron modelos para detectar dificultades académicas en secundaria y excluyeron uno de ellos al identificar un sesgo que el equipo no logró corregir. Ese examen orientó una decisión sobre el modelo. Para establecer sus efectos sobre las trayectorias habría que seguir también las actuaciones posteriores a la alerta, los apoyos recibidos y las oportunidades que los estudiantes conservaron. La distinción es decisiva para interpretar los resultados: una auditoría predictiva estudia cómo se producen y distribuyen las clasificaciones, mientras que una evaluación institucional examina qué cambia cuando se actúa a partir de ellas (Baker & Hawn, 2022; Queiroga et al., 2022).

De estos antecedentes se deriva un criterio para el diseño institucional. Toda categoría de seguimiento debería estar vinculada con un propósito, un período de vigencia y una persona responsable de revisarla. También conviene distinguir quién necesita conocer la alerta para prestar un apoyo y quién puede cumplir su función con información agregada. Cuando la clasificación deja de ser pertinente, corresponde revisar su visibilidad y conservación según la finalidad y las obligaciones aplicables. El estudiante, por su parte, necesita una vía para contextualizar el resultado o cuestionar sus consecuencias, especialmente si la categoría se utiliza fuera de la situación que la originó (LOPDP, 2021, arts. 10, 14 y 20–21; Prinsloo & Slade, 2016).

La vigilancia y el etiquetado se vuelven más difíciles de controlar cuando la institución desconoce qué registra la herramienta, cuánto tiempo lo conserva o quién puede reutilizarlo. Esa dificultad desplaza la discusión hacia las responsabilidades de quienes contratan, configuran y operan los servicios. El apartado 4.5 examinará cómo se distribuyen esas responsabilidades entre la institución y sus proveedores, y qué condiciones deben quedar establecidas para que el uso efectivo de los datos corresponda a la finalidad educativa declarada (Human Rights Watch, 2022; LOPDP, 2021).

Responsabilidades institucionales y relaciones con proveedores tecnológicos.

La contratación de una plataforma educativa reúne decisiones que suelen examinarse por separado. La institución define para qué necesita los datos, qué evidencia considera suficiente para orientar un apoyo y quién puede actuar a partir de una predicción. El proveedor configura funciones que condicionan esas decisiones, entre ellas los registros que se generan, las categorías que muestra el panel y los permisos de acceso. La responsabilidad institucional consiste en mantener la correspondencia entre el propósito pedagógico, el tratamiento de los datos y las actuaciones que se derivan del sistema. En un estudio realizado en universidades de Chile y Ecuador, Hilliger et al. (2020) identificaron dificultades relacionadas con la fiabilidad de los sistemas de información y las políticas de uso de datos. Ambas condiciones deben examinarse antes de incorporar una herramienta al acompañamiento estudiantil.

En Ecuador, la distribución de responsabilidades parte de las funciones que cada actor cumple en el tratamiento. La Ley Orgánica de Protección de Datos Personales distingue al responsable, que decide sobre la finalidad y el tratamiento de los datos, del encargado, que los trata por cuenta del responsable. Si una institución determina la finalidad del seguimiento académico y contrata a un proveedor para procesar los registros conforme a sus instrucciones, la relación debe quedar regulada por un contrato. Cuando el proveedor pretende utilizar esa información para fines propios, como entrenar un modelo comercial, corresponde examinar ese uso por separado y determinar su legitimación. La denominación que figure en el contrato debe corresponder a las actividades que cada parte realiza (Ley Orgánica de Protección de Datos Personales [LOPDP], 2021, arts. 4, 7, 10 y 34).

La Superintendencia de Protección de Datos Personales (2025) regula la incorporación de cláusulas de protección de datos en las relaciones

contractuales comprendidas en la Resolución SPDP-SPD-2025-0006-R. En una contratación educativa, esto se traduce en precisar qué información puede utilizar el proveedor, para qué operaciones, durante cuánto tiempo y bajo qué condiciones de confidencialidad y seguridad. Conviene identificar también los servicios subcontratados que intervienen en el tratamiento y establecer cómo cooperará el proveedor ante solicitudes de acceso, rectificación o revisión. Estas condiciones permiten comprobar si la configuración real del servicio corresponde a lo que la institución autorizó y comunicó a la comunidad educativa (LOPDP, 2021, arts. 12, 34 y 37).

La supervisión del proveedor comprende también las prestaciones educativas del sistema. La validación analizada en el capítulo 2 ofrece un criterio para la contratación. Si una herramienta genera alertas, la institución necesita conocer qué resultado predice, con qué población se evaluó y en qué momento estarán disponibles las estimaciones. Una modificación de las variables, los umbrales o las categorías del panel puede cambiar quién recibe una alerta y quién queda fuera del seguimiento. Por ello, se propone acordar mecanismos para comunicar los cambios relevantes y someterlos a revisión antes de incorporarlos a decisiones académicas. La experiencia de adaptación de paneles en universidades latinoamericanas muestra que sus funciones deben ajustarse a los objetivos, los usuarios y los momentos en que se toman las decisiones de orientación (Guerra et al., 2020; von Hippel & Hofflinger, 2021).

El capítulo 3 situó la mediación docente en la interpretación de la información y la revisión de los apoyos. Para ejercerla, el profesorado y los equipos de orientación necesitan conocer el alcance de los indicadores y disponer de tiempo y atribuciones para valorar cada caso. La institución debe definir quién revisa una alerta, quién decide la actuación y quién atiende las observaciones del estudiante. Al proveedor le corresponde facilitar, en los términos acordados, la información técnica que permita reconstruir el resultado. La explicación de la decisión educativa recae en la instancia que la tomó y debe mostrar cómo valoró la información disponible. Esta distribución permite que la revisión tenga efectos sobre la decisión cuando se detecta un error o se aporta información relevante (Guerra et al., 2020; Prinsloo & Slade, 2016; LOPDP, 2021, art. 20).

La gobernanza abarca también la terminación del servicio. El artículo 34 de la LOPDP prevé la devolución o destrucción de los datos personales una vez cumplida la prestación contractual. En educación, preparar esa salida implica distinguir los registros que la institución debe conservar para dar continuidad a la trayectoria académica de las copias que el proveedor trata para prestar el

servicio. Los acuerdos deben permitir verificar qué información se devuelve, en qué formato y cómo se acredita la eliminación cuando corresponda. Planificar esta etapa desde la contratación protege la continuidad de los apoyos y limita la circulación posterior de perfiles que han perdido su finalidad (LOPDP, 2021, arts. 10 y 34; Superintendencia de Protección de Datos Personales, 2025).

La relación con el proveedor permite reunir las preguntas que han guiado el libro. La calidad de los registros condiciona lo que puede inferirse sobre el aprendizaje. La validación determina cuánto fundamento tiene una predicción. La organización del acompañamiento y la mediación docente determinan qué puede hacerse con ella y qué margen conserva el estudiante para participar o cuestionar una decisión. El contrato puede asegurar acceso a documentación y fijar obligaciones de cooperación. Cumplirlas en la práctica exige equipos que sepan interpretar los resultados, atender solicitudes y sostener los apoyos ofrecidos. El apartado 4.6 examinará esas capacidades en los contextos latinoamericanos y ecuatorianos, donde la pertinencia de una herramienta depende también de las condiciones institucionales en que se incorpora (Guerra et al., 2020; Hilliger et al., 2020; LOPDP, 2021, arts. 20 y 34).

Condiciones de implementación en contextos latinoamericanos y ecuatorianos.

Las responsabilidades institucionales y las condiciones contractuales examinadas en el apartado anterior delimitan quién puede tratar los datos y con qué fines. Su aplicación cotidiana depende de que la institución disponga de registros fiables, reglas para utilizarlos y personal capaz de intervenir cuando una alerta lo requiera. En dos universidades chilenas y dos ecuatorianas, Hilliger, Ortiz-Rojas, Pesántez-Cabrera, Scheihing, Tsai, Muñoz-Merino, Broos, Whitelock-Wainwright y Pérez-Sanagustín (2020b) identificaron dificultades relacionadas con la fiabilidad de los sistemas de información y la falta de políticas institucionales sobre el uso de datos. En esas mismas universidades, los estudiantes señalaron la necesidad de recibir retroalimentación y apoyo oportunos, mientras que el profesorado necesitaba alertas útiles para orientar su trabajo y los equipos directivos requerían información para organizar las intervenciones (Hilliger et al., 2020a). La puesta en marcha de un sistema de analítica debe partir, por ello, de una decisión pedagógica concreta y de la capacidad institucional para actuar sobre ella (Hilliger et al., 2020a).

En Ecuador, el porcentaje de hogares con acceso a internet aumentó del 66,0 % en julio de 2024 al 71,3 % en julio de 2025 (Instituto Nacional de Estadística y Censos [INEC], 2025). Esa cifra nacional mide el acceso en el hogar. Para

establecer si una actividad digital puede integrarse de manera regular a la enseñanza, la institución necesita conocer además la disponibilidad de equipos y las condiciones en las que sus estudiantes se conectan. El diagnóstico ecuatoriano de preparación para la inteligencia artificial documentó diferencias de conectividad entre zonas urbanas y rurales, una razón para comprobar estas condiciones en cada sede y modalidad antes de exigir una vía única de participación digital (UNESCO, 2025).

La desigualdad de acceso incide también en la interpretación de los registros. Si un sistema estima el riesgo académico a partir de los ingresos a la plataforma y las entregas en línea, una actividad baja puede reflejar dificultades de conexión o trabajo realizado por otros medios. Esta es una implicación metodológica de emplear registros digitales en contextos con brechas de acceso y sistemas de información de fiabilidad desigual (Hilliger et al., 2020b; UNESCO, 2025). Antes de convertir una alerta en una decisión de seguimiento, conviene contrastarla con las evidencias de aprendizaje disponibles y con la información que aporte el estudiante. Ese contraste permite orientar el apoyo hacia la dificultad que se busca atender y corregir interpretaciones basadas en registros incompletos (Hilliger et al., 2020a, 2020b).

La formación del profesorado debe corresponder a las decisiones que el sistema pone en sus manos. Si su tarea consiste en revisar alertas, necesita conocer los registros que las originan, las limitaciones de esos datos y el procedimiento para corregir una interpretación. Esta prioridad se desprende de los problemas de fiabilidad y de regulación interna observados en las universidades estudiadas por Hilliger et al. (2020b). La institución, por su parte, debe asignar tiempo para verificar las alertas y definir quién se comunicará con el estudiante, qué apoyo podrá ofrecerle y quién hará el seguimiento. Estas tareas traducen la demanda de información oportuna en una respuesta que el equipo docente o de acompañamiento puede sostener (Hilliger et al., 2020a).

La evaluación de un piloto permite examinar esas condiciones antes de ampliar el uso del sistema. En la dimensión predictiva, interesa comprobar qué grupos quedan insuficientemente representados en los registros y si los errores se concentran en alguna sede o modalidad. Este examen resulta pertinente cuando las condiciones de acceso y la calidad de los sistemas de información varían entre instituciones (Hilliger et al., 2020b; UNESCO, 2025). En la dimensión pedagógica, cabe valorar cuántas alertas se traducen en apoyos, si estos llegan a tiempo y cuánto trabajo exige revisar cada caso. La pertinencia de esas medidas se deriva de las necesidades diferenciadas de estudiantes, docentes y

directivos identificadas en el estudio regional (Hilliger et al., 2020a). Incorporar sus perspectivas durante el piloto permite además identificar qué recomendaciones se comprenden, qué errores pueden corregirse y qué dificultades persisten al utilizar la herramienta (Hilliger et al., 2020a, 2020b).

Un resultado favorable en una sede ofrece evidencia sobre las condiciones en las que se obtuvo. Antes de trasladar el sistema a otra institución, corresponde verificar si los registros son comparables, si existe capacidad para atender las alertas y si los estudiantes cuentan con vías efectivas para acceder al apoyo. Esta revisión se justifica por las diferencias de infraestructura descritas en Ecuador y por los problemas de fiabilidad de los registros y de regulación interna identificados en el estudio universitario (Hilliger et al., 2020b; UNESCO, 2025). El apartado 4.7 retoma estas condiciones para distinguir cuándo la evidencia permite adoptar o ampliar un sistema, cuándo corresponde revisar su diseño y cuándo debe retirarse para preservar la finalidad educativa que motivó su incorporación (Hilliger et al., 2020a, 2020b; UNESCO, 2025).

Criterios para adoptar, evaluar, revisar o retirar un sistema.

La decisión de adoptar un sistema de analítica del aprendizaje o de inteligencia artificial debe partir de una necesidad educativa delimitada y de una intervención que la institución esté en condiciones de ofrecer. En dos universidades chilenas y dos ecuatorianas, los estudiantes señalaron la necesidad de recibir retroalimentación y apoyo oportunos, mientras que los docentes y los equipos directivos requerían información para orientar y organizar las intervenciones (Hilliger et al., 2020a). Antes de contratar una herramienta, conviene precisar qué decisión se espera mejorar, quién podrá actuar a partir de sus resultados y con qué evidencia se juzgará su contribución frente a la práctica vigente (Hilliger et al., 2020a; Tabassi, 2023).

La autorización de un piloto exige justificar la pertinencia de los datos y la proporcionalidad de su tratamiento respecto del propósito declarado (UNESCO, 2021). En Ecuador, las diferencias territoriales de conectividad documentadas en el diagnóstico nacional de preparación para la inteligencia artificial hacen necesario comprobar qué actividades quedan fuera del registro digital y si esa omisión afecta con mayor frecuencia a determinados grupos (UNESCO, 2025). La fiabilidad de los sistemas de información también condiciona la interpretación de los registros, como mostró el estudio de Hilliger et al. (2020b) en universidades de Chile y Ecuador. Estas condiciones delimitan el alcance del piloto. Un resultado obtenido en sedes con conectividad estable y equipos de

acompañamiento disponibles ofrece evidencia sobre esas sedes. La ampliación a otros entornos requiere verificar allí la calidad de los datos y la capacidad de respuesta institucional (Tabassi, 2023).

La evaluación de un sistema de alerta temprana debe distinguir el desempeño predictivo, la ejecución del apoyo y el resultado educativo. En el plano predictivo, interesa estimar cuántos casos quedan sin detectar, cuántas alertas resultan injustificadas y cómo se distribuyen los errores entre los grupos para los que existe información suficiente (Tabassi, 2023). En el plano operativo, corresponde verificar qué proporción de alertas se revisa, cuánto tiempo transcurre hasta el contacto y qué apoyos se ofrecen efectivamente. Estos indicadores trasladan a la evaluación la necesidad de acompañamiento oportuno identificada por Hilliger et al. (2020a). En el plano educativo, se examina si la intervención contribuyó al resultado que motivó su adopción. La atribución de una mejora al sistema depende de que el diseño de evaluación permita distinguir su contribución de otros cambios ocurridos durante el mismo período (Tabassi, 2023).

Separar estos planos permite localizar la causa de un resultado insuficiente. Si el modelo detecta casos con antelación, pero las alertas se acumulan, la revisión debe examinar los plazos, la disponibilidad del personal y las rutas de acompañamiento (Hilliger et al., 2020a; Tabassi, 2023). Si los errores se concentran en un grupo, corresponde revisar la cobertura y calidad de los registros, la definición del desenlace y el desempeño del modelo en esa población (Hilliger et al., 2020b; Tabassi, 2023). Ajustar el umbral de alerta es una decisión que también compromete recursos. El número de casos que el equipo puede revisar dentro de un plazo útil debe considerarse junto con las consecuencias de omitir a estudiantes que requieren apoyo (Hilliger et al., 2020a; Tabassi, 2023).

En los sistemas de personalización, la frecuencia de uso permite describir la interacción con la herramienta. Para juzgar su aporte pedagógico, interesa comprobar si la retroalimentación ayuda a revisar el propio trabajo, si el apoyo responde a la dificultad identificada y si el estudiante conserva acceso a actividades de mayor complejidad (Hilliger et al., 2020a; UNESCO, 2021). La evaluación debe incluir el tiempo que el profesorado dedica a verificar recomendaciones, corregir errores y ajustar recursos, porque de ese trabajo depende parte de la capacidad institucional para sostener la intervención (Tabassi, 2023). También debe examinarse si el estudiante puede comprender y

cuestionar una recomendación cuando esta influye en las oportunidades que se le ofrecen (UNESCO, 2021).

La siguiente tabla sintetiza las decisiones que la institución debe poder justificar durante el ciclo de uso. Los criterios de evaluación, revisión y suspensión deben establecerse antes del piloto, con exigencias proporcionales a las consecuencias de un error y a la posibilidad de corregirlo (Tabassi, 2023; UNESCO, 2021).

Tabla 9

Criterios institucionales para decidir sobre el uso de un sistema de analítica del aprendizaje o de inteligencia artificial

Decisión	Evidencia que debe examinarse	Actuación institucional
Autorizar un piloto	Necesidad educativa definida, datos pertinentes, riesgos evaluados y capacidad para brindar el apoyo previsto.	Delimitar la población, el período y los usos permitidos. Asignar responsables y fijar condiciones de evaluación y suspensión.
Mantener o ampliar	Beneficio educativo documentado, distribución de errores examinada y capacidad de atención suficiente.	Mantener el uso en las condiciones evaluadas. Comprobar su funcionamiento en las nuevas sedes o modalidades antes de ampliarlo.
Revisar	Deterioro del desempeño, errores concentrados en determinados grupos, alertas sin atender o carga docente superior a la prevista.	Identificar si la dificultad se origina en los datos, el modelo o la intervención. Verificar el efecto de las correcciones antes de ampliar el uso.
Suspender	Riesgo grave para los estudiantes, incidente que compromete los datos o imposibilidad de ejercer la supervisión prevista.	Interrumpir el uso que origina el riesgo, sostener el acompañamiento por otra vía y establecer las condiciones para una eventual reanudación.
Retirar	Ausencia persistente de beneficio, daños que la institución no puede mitigar o pérdida de las condiciones	Ejecutar el plan de salida, mantener la continuidad de los apoyos y resolver la conservación o eliminación de los registros

	necesarias para un uso responsable.	conforme a las obligaciones aplicables.

Nota. Elaboración propia a partir de Hilliger et al. (2020a, 2020b), Tabassi (2023) y UNESCO (2021).

La revisión debe realizarse a intervalos previstos y cuando cambien las fuentes de datos, las reglas académicas, la población atendida o la versión del producto. Esos cambios pueden modificar la validez de las estimaciones y el alcance de los riesgos evaluados al inicio (Tabassi, 2023). Cuando un resultado influye en una decisión individual, la institución debe poder reconstruir qué información se utilizó, quién interpretó el resultado y cómo se atendió una objeción (Tabassi, 2023; UNESCO, 2021). La explicación cumple así una función concreta: permite determinar si corresponde corregir un registro, reconsiderar una decisión o reparar sus efectos (UNESCO, 2021).

El retiro del sistema debe preverse desde la contratación, pues los procesos de acompañamiento pueden llegar a depender de él. El plan de salida debe establecer cómo se mantendrá la atención, qué accesos se revocarán y qué registros deberán conservarse para atender obligaciones de revisión o rendición de cuentas (Tabassi, 2023). También conviene comprobar si las clasificaciones anteriores siguen visibles en expedientes o paneles y si continúan influyendo en la asignación de apoyos. Cuando una clasificación errónea afectó una decisión académica, el retiro de la herramienta debe acompañarse de una revisión de esa decisión y de sus consecuencias para el estudiante (Tabassi, 2023; UNESCO, 2021).

El recorrido del libro comenzó con los registros que deja la actividad educativa y concluye con las decisiones que se toman a partir de ellos. Entre ambos momentos intervienen elecciones que comprometen a la institución: qué se mide, cómo se interpreta la información y qué apoyo puede ofrecerse a partir de ella (Hilliger et al., 2020a, 2020b). La predicción adquiere valor pedagógico cuando permite reconocer una necesidad con tiempo suficiente para actuar (Hilliger et al., 2020a). La personalización se justifica cuando el apoyo amplía las oportunidades de aprender y el estudiante puede participar en las decisiones que afectan su trayectoria (Hilliger et al., 2020a; UNESCO, 2021). La gobernanza convierte esas exigencias en responsabilidades que pueden verificarse y revisarse durante todo el uso del sistema (Tabassi, 2023; UNESCO, 2021).

En los contextos latinoamericanos y ecuatorianos examinados, la conectividad, la calidad de los registros y la capacidad de acompañamiento condicionan quién queda representado en los datos y quién recibe el apoyo (Hilliger et al., 2020b; UNESCO, 2025). Por eso, la justificación educativa de un sistema se decide también después de que aparece una alerta o se genera una recomendación. Importa si alguien pudo actuar a tiempo, si el estudiante encontró una oportunidad efectiva para continuar aprendiendo y si tuvo una vía para cuestionar una interpretación equivocada. Son consecuencias que la institución debe poder documentar y por las que debe responder al decidir si mantiene, modifica o retira el sistema (Hilliger et al., 2020a; Tabassi, 2023; UNESCO, 2021).

CONCLUSIONES

Un registro digital adquiere valor educativo cuando se interpreta en relación con la actividad que lo produjo. La frecuencia de acceso, el tiempo en una plataforma o la entrega de una tarea describen conductas observables. Para inferir algo sobre la comprensión o el progreso, es preciso justificar qué relación guarda cada indicador con el aprendizaje y qué parte de la actividad queda fuera del registro. La calidad de la analítica depende, desde su origen, de la pertinencia de esa relación y de la fiabilidad de los datos que la sustentan (Hilliger et al., 2020a, 2020b).

Una estimación de riesgo sitúa al estudiante ante un desenlace posible bajo las condiciones observadas. Su utilidad depende de la antelación con que se genera, de la distribución de los errores y del margen de actuación que ofrece al equipo educativo (Tabassi, 2023). Por ello, la evaluación debe seguir el recorrido completo de la alerta, desde su emisión hasta el apoyo efectivamente prestado. Si la institución puede identificar una dificultad, pero carece de tiempo o recursos para atenderla, la limitación se encuentra en la capacidad de intervención y exige una respuesta organizativa (Hilliger et al., 2020a).

Personalizar la enseñanza exige conservar la posibilidad de revisar el itinerario propuesto. La mediación docente permite interpretar las recomendaciones a la luz del trabajo del estudiante, ajustar el grado de apoyo y mantener abiertas oportunidades de mayor complejidad (Hilliger et al., 2020a; UNESCO, 2021). El resultado debe valorarse por la calidad de las oportunidades que se abren y por el margen que conserva el estudiante para comprender la orientación recibida, tomar decisiones y asumir progresivamente la regulación de su aprendizaje (UNESCO, 2021).

La gobernanza se concreta en la capacidad institucional de justificar el uso de los datos, examinar a quiénes beneficia o perjudica el sistema y corregir las decisiones que afectan la trayectoria de un estudiante (Tabassi, 2023; UNESCO, 2021). En Ecuador, las diferencias de conectividad y de capacidad institucional hacen que esa justificación deba comprobarse en cada contexto de implementación (Hilliger et al., 2020b; UNESCO, 2025). La autorización debe revisarse cuando cambian esas condiciones. Si el beneficio educativo deja de sostenerse o la institución pierde la capacidad de proteger a los estudiantes, corresponde suspender o retirar el sistema y asegurar la continuidad del acompañamiento (Tabassi, 2023).

REFERENCIAS

Alalawi, K., Athauda, R., Chiong, R., & Renner, I. (2025). Evaluating the student performance prediction and action framework through a learning analytics intervention study. *Education and Information Technologies, 30*, 2887–2916. https://doi.org/10.1007/s10639-024-12923-5

Aleven, V., McLaughlin, E. A., Glenn, R. A., & Koedinger, K. R. (2017). Instruction based on adaptive learning technologies. In R. E. Mayer & P. A. Alexander (Eds.), *Handbook of research on learning and instruction* (2nd ed., pp. 522–560). Routledge. https://www.cs.cmu.edu/~aleven/Papers/2016/Aleven_etal_Handbook2017_AdaptiveLearningTechnologies.pdf

Anijovich, R. (2014). *Gestionar una escuela con aulas heterogéneas: Enseñar y aprender en la diversidad*. Paidós. https://www.planetadelibros.com.ar/libro-gestionar-una-escuela-con-aulas-heterogeneas/131856

Anijovich, R., & Cappelletti, G. (2020). La retroalimentación formativa: Una oportunidad para mejorar los aprendizajes y la enseñanza. *Revista Docencia Universitaria, 21*(1), 81–96. https://revistas.uis.edu.co/index.php/revistadocencia/article/view/11327

Arévalo-Cordovilla, F. E., & Peña, M. (2025). Evaluating ensemble models for fair and interpretable prediction in higher education using multimodal data. *Scientific Reports, 15*, Article 29420. https://doi.org/10.1038/s41598-025-15388-9

Baker, R. S., & Hawn, A. (2022). Algorithmic bias in education. *International Journal of Artificial Intelligence in Education, 32*, 1052–1092. https://doi.org/10.1007/s40593-021-00285-9

Bastani, H., Bastani, O., Sungu, A., Ge, H., Kabakcı, Ö., & Mariman, R. (2025). Generative AI without guardrails can harm learning: Evidence from high school mathematics. *Proceedings of the National Academy of Sciences, 122*(26), Article e2422633122. https://doi.org/10.1073/pnas.2422633122

Bernacki, M. L., Greene, M. J., & Lobczowski, N. G. (2021). A systematic review of research on personalized learning: Personalized by whom, to what, how,

and for what purpose(s)? *Educational Psychology Review, 33*, 1675–1715. https://doi.org/10.1007/s10648-021-09615-8

Black, P., & Wiliam, D. (2009). Developing the theory of formative assessment. *Educational Assessment, Evaluation and Accountability, 21*(1), 5–31. https://doi.org/10.1007/s11092-008-9068-5

Bond, M., Khosravi, H., De Laat, M., Bergdahl, N., Negrea, V., Oxley, E., Pham, P., Chong, S. W., & Siemens, G. (2024). A meta systematic review of artificial intelligence in higher education: A call for increased ethics, collaboration, and rigour. *International Journal of Educational Technology in Higher Education, 21*, Article 4. https://doi.org/10.1186/s41239-023-00436-z

Carless, D., & Boud, D. (2018). The development of student feedback literacy: Enabling uptake of feedback. *Assessment & Evaluation in Higher Education, 43*(8), 1315–1325. https://doi.org/10.1080/02602938.2018.1463354

Cechinel, C., Ochoa, X., Lemos dos Santos, H., Carvalho Nunes, J. B., Rodés, V., & Marques Queiroga, E. (2020). Mapping learning analytics initiatives in Latin America. *British Journal of Educational Technology, 51*(4), 892–914. https://doi.org/10.1111/bjet.12941

Coll, C. (2017). De la atención a la diversidad a la personalización del aprendizaje. *Aula de Innovación Educativa*, (267), 29–33. https://grintieproduccions.psyed.edu.es/r/coll-2017-de-la-atencion-a-la-diversidad-a-la-personalizacion-del-aprendizaje/

Comité de los Derechos del Niño. (2021). *Observación general núm. 25 (2021) relativa a los derechos de los niños en relación con el entorno digital* (CRC/C/GC/25). Naciones Unidas. https://docstore.ohchr.org/SelfServices/FilesHandler.ashx?enc=x7LeWB3%2FaiMax0p4S2KaoZjMOBT0j62qRQ4XIG5LXRMTGM0JJj9ryetW52VfZLem6xrubF9bxADFR1x0xYAxQg%3D%3D

Díaz Barriga Arceo, F. (2003). Cognición situada y estrategias para el aprendizaje significativo. *Revista Electrónica de Investigación Educativa, 5*(2), 1–13. https://redie.uabc.mx/redie/article/view/85

Drachsler, H., Verbert, K., Santos, O. C., & Manouselis, N. (2015). Panorama of recommender systems to support learning. In F. Ricci, L. Rokach, & B.

Shapira (Eds.), *Recommender systems handbook* (2nd ed., pp. 421–451). Springer. https://doi.org/10.1007/978-1-4899-7637-6_12

Education Endowment Foundation. (2024). *ChatGPT in lesson preparation: Teacher Choices trial*. https://educationendowmentfoundation.org.uk/projects-and-evaluation/projects/choices-in-edtech-using-generative-ai-chatgpt-for-ks3-science-lesson-preparation-2024-teacher-choices-trial

Gašević, D., Dawson, S., Rogers, T., & Gasevic, D. (2016). Learning analytics should not promote one size fits all: The effects of instructional conditions in predicting academic success. *The Internet and Higher Education, 28*, 68–84. https://doi.org/10.1016/j.iheduc.2015.10.002

Gašević, D., Dawson, S., & Siemens, G. (2015). Let's not forget: Learning analytics are about learning. *TechTrends, 59*(1), 64–71. https://doi.org/10.1007/s11528-014-0822-x

Global Education Monitoring Report Team. (2023). *Global education monitoring report 2023: Technology in education: A tool on whose terms?* UNESCO. https://doi.org/10.54676/UZQV8501

Goldhammer, F., Hahnel, C., Kroehne, U., & Zehner, F. (2021). From byproduct to design factor: On validating the interpretation of process indicators based on log data. *Large-scale Assessments in Education, 9*, Article 20. https://doi.org/10.1186/s40536-021-00113-5

Greller, W., & Drachsler, H. (2012). Translating learning into numbers: A generic framework for learning analytics. *Educational Technology & Society, 15*(3), 42–57. https://research.ou.nl/en/publications/translating-learning-into-numbers-a-generic-framework-for-learnin/

Guerra, J., Ortiz-Rojas, M., Zúñiga-Prieto, M. A., Scheihing, E., Jiménez, A., Broos, T., De Laet, T., & Verbert, K. (2020). Adaptation and evaluation of a learning analytics dashboard to improve academic support at three Latin American universities. *British Journal of Educational Technology, 51*(4), 973–1001. https://doi.org/10.1111/bjet.12950

Guzmán-Valenzuela, C., Gómez-González, C., Rojas-Murphy Tagle, A., & Lorca-Vyhmeister, A. (2021). Learning analytics in higher education: A preponderance of analytics but very little learning? *International Journal of*

Educational Technology in Higher Education, 18, Article 23. https://doi.org/10.1186/s41239-021-00258-x

Herodotou, C., Naydenova, G., Boroowa, A., Gilmour, A., & Rienties, B. (2020). How can predictive learning analytics and motivational interventions increase student retention and enhance administrative support in distance education? *Journal of Learning Analytics, 7*(2), 72–83. https://doi.org/10.18608/jla.2020.72.4

Hilliger, I., Ortiz-Rojas, M., Pesántez-Cabrera, P., Scheihing, E., Tsai, Y.-S., Muñoz-Merino, P. J., Broos, T., Whitelock-Wainwright, A., Gašević, D., & Pérez-Sanagustín, M. (2020). Towards learning analytics adoption: A mixed methods study of data-related practices and policies in Latin American universities. *British Journal of Educational Technology, 51*(4), 915–937. https://doi.org/10.1111/bjet.12933

Hilliger, I., Ortiz-Rojas, M., Pesántez-Cabrera, P., Scheihing, E., Tsai, Y.-S., Muñoz-Merino, P. J., Broos, T., Whitelock-Wainwright, A., & Pérez-Sanagustín, M. (2020). Identifying needs for learning analytics adoption in Latin American universities: A mixed-methods approach. *The Internet and Higher Education, 45*, Article 100726. https://doi.org/10.1016/j.iheduc.2020.100726

Human Rights Watch. (2022). *"How dare they peep into my private life?" Children's rights violations by governments that endorsed online learning during the Covid-19 pandemic*. https://www.hrw.org/report/2022/05/25/how-dare-they-peep-my-private-life/childrens-rights-violations-governments

Ifenthaler, D., Gibson, D., Prasse, D., Shimada, A., & Yamada, M. (2021). Putting learning back into learning analytics: Actions for policy makers, researchers, and practitioners. *Educational Technology Research and Development, 69*, 2131–2150. https://doi.org/10.1007/s11423-020-09909-8

Ifenthaler, D., & Yau, J. Y.-K. (2020). Utilising learning analytics to support study success in higher education: A systematic review. *Educational Technology Research and Development, 68*, 1961–1990. https://doi.org/10.1007/s11423-020-09788-z

Instituto Internacional de Planeamiento de la Educación de la UNESCO. (2025, 21 de febrero). *Inteligencia artificial y educación: El rol de la IA en las*

políticas educativas. https://www.iiep.unesco.org/es/articles/inteligencia-artificial-y-educacion-el-rol-de-la-ia-en-las-politicas-educativas

Instituto Nacional de Estadística y Censos. (2025). *Tecnologías de la información y comunicación (TIC)* https://www.ecuadorencifras.gob.ec/tecnologias-de-la-informacion-y-comunicacion-tic/

Kapoor, S., & Narayanan, A. (2023). Leakage and the reproducibility crisis in machine-learning-based science. *Patterns, 4*(9), Article 100804. https://doi.org/10.1016/j.patter.2023.100804

Kestin, G., Miller, K., Klales, A., Milbourne, T., & Ponti, G. (2025). AI tutoring outperforms in-class active learning: An RCT introducing a novel research-based design in an authentic educational setting. *Scientific Reports, 15*, Article 17458. https://doi.org/10.1038/s41598-025-97652-6

Larrabee Sønderlund, A., Hughes, E., & Smith, J. (2019). The efficacy of learning analytics interventions in higher education: A systematic review. *British Journal of Educational Technology, 50*(5), 2594–2618. https://doi.org/10.1111/bjet.12720

Ley Orgánica de Protección de Datos Personales, Quinto Suplemento del Registro Oficial No. 459 (26 de mayo de 2021) (Ecuador). https://www.gob.ec/sites/default/files/regulations/2025-01/01%20Ley%20Org%C3%A1nica%20de%20Protecci%C3%B3n%20de%20Datos%20Personales.pdf

Liu, Y., Wang, W., & Xu, E. (2025). The effectiveness of learning analytics-based interventions in enhancing students' learning effect: A meta-analysis of empirical studies. *SAGE Open, 15*(2). https://doi.org/10.1177/21582440251336707

Ma, W., Adesope, O. O., Nesbit, J. C., & Liu, Q. (2014). Intelligent tutoring systems and learning outcomes: A meta-analysis. *Journal of Educational Psychology, 106*(4), 901–918. https://doi.org/10.1037/a0037123

Maldonado-Mahauad, J., Pérez-Sanagustín, M., Kizilcec, R. F., Morales, N., & Munoz-Gama, J. (2018). Mining theory-based patterns from Big data: Identifying self-regulated learning strategies in Massive Open Online Courses. *Computers in Human Behavior, 80*, 179–196. https://doi.org/10.1016/j.chb.2017.11.011

Matcha, W., Uzir, N. A., Gašević, D., & Pardo, A. (2020). A systematic review of empirical studies on learning analytics dashboards: A self-regulated learning perspective. *IEEE Transactions on Learning Technologies, 13*(2), 226–245. https://doi.org/10.1109/TLT.2019.2916802

Miao, F., & Holmes, W. (2023). *Guidance for generative AI in education and research*. UNESCO. https://doi.org/10.54675/EWZM9535

Miller, T. (2019). Explanation in artificial intelligence: Insights from the social sciences. *Artificial Intelligence, 267*, 1–38. https://doi.org/10.1016/j.artint.2018.07.007

Ochoa, X. (2017). Multimodal learning analytics. In C. Lang, G. Siemens, A. F. Wise, & D. Gašević (Eds.), *Handbook of learning analytics* (pp. 129–141). Society for Learning Analytics Research. https://doi.org/10.18608/hla17.011

Panadero, E. (2017). A review of self-regulated learning: Six models and four directions for research. *Frontiers in Psychology, 8*, Article 422. https://doi.org/10.3389/fpsyg.2017.00422

Pardo, A., Jovanovic, J., Dawson, S., Gašević, D., & Mirriahi, N. (2019). Using learning analytics to scale the provision of personalised feedback. *British Journal of Educational Technology, 50*(1), 128–138. https://doi.org/10.1111/bjet.12592

Paulsen, L., & Lindsay, E. (2024). Learning analytics dashboards are increasingly becoming about learning and not just analytics—A systematic review. *Education and Information Technologies, 29*, 14279–14308. https://doi.org/10.1007/s10639-023-12401-4

Prinsloo, P., & Slade, S. (2016). Student vulnerability, agency and learning analytics: An exploration. *Journal of Learning Analytics, 3*(1), 159–182. https://doi.org/10.18608/jla.2016.31.10

Queiroga, E. M., Batista Machado, M. F., Paragarino, V. R., Primo, T. T., & Cechinel, C. (2022). Early prediction of at-risk students in secondary education: A countrywide K-12 learning analytics initiative in Uruguay. *Information, 13*(9), Article 401. https://doi.org/10.3390/info13090401

Reeve, J., & Tseng, C.-M. (2011). Agency as a fourth aspect of students' engagement during learning activities. *Contemporary Educational Psychology, 36*(4), 257–267. https://doi.org/10.1016/j.cedpsych.2011.05.002

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

Ryan, R. M., & Deci, E. L. (2020). Intrinsic and extrinsic motivation from a self-determination theory perspective: Definitions, theory, practices, and future directions. *Contemporary Educational Psychology, 61*, Article 101860. https://doi.org/10.1016/j.cedpsych.2020.101860

Saito, T., & Rehmsmeier, M. (2015). The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLOS ONE, 10*(3), Article e0118432. https://doi.org/10.1371/journal.pone.0118432

Sánchez-Mendiola, M., Moreno-Salinas, J. G., Bautista-Godínez, T., & Martínez-González, A. (2019). La analítica del aprendizaje en educación médica: ¿punto de inflexión? *Gaceta Médica de México, 155*(1), 90–100. https://www.scielo.org.mx/scielo.php?script=sci_arttext\&pid=S0016-38132019000100090

Scheffel, M., Drachsler, H., Stoyanov, S., & Specht, M. (2014). Quality indicators for learning analytics. *Educational Technology & Society, 17*(4), 117–132. https://research.ou.nl/en/publications/quality-indicators-for-learning-analytics/

Scholes, V. (2016). The ethics of using learning analytics to categorize students on risk. *Educational Technology Research and Development, 64*(5), 939–955. https://doi.org/10.1007/s11423-016-9458-1

Slade, S., & Prinsloo, P. (2013). Learning analytics: Ethical issues and dilemmas. *American Behavioral Scientist, 57*(10), 1510–1529. https://doi.org/10.1177/0002764213479366

Sousa, E. B. G., Alexandre, B., Ferreira Mello, R., Pontual Falcão, T., Vesin, B., & Gašević, D. (2021). Applications of learning analytics in high schools: A

systematic literature review. *Frontiers in Artificial Intelligence, 4*, Article 737891. https://doi.org/10.3389/frai.2021.737891

Superintendencia de Protección de Datos Personales. (2025, 30 de abril). *Reglamento que establece la obligación de incorporar cláusulas de protección de datos personales en los contratos celebrados dentro del territorio de la República del Ecuador* (Resolución SPDP-SPD-2025-0006-R). https://www.spdp.gob.ec/wp-content/uploads/2025/12/06.01.01-SPDP-SPD-2025-0006-R-clausulas-para-contratos-en-Ecuador-signed_compressed.pdf

Tabassi, E. (2023). *Artificial intelligence risk management framework (AI RMF 1.0)* (NIST AI 100-1). National Institute of Standards and Technology. https://doi.org/10.6028/NIST.AI.100-1

Tetzlaff, L., Schmiedek, F., & Brod, G. (2021). Developing personalized education: A dynamic framework. *Educational Psychology Review, 33*, 863–882. https://doi.org/10.1007/s10648-020-09570-w

UNESCO. (2021, 23 de noviembre). *Recomendación sobre la ética de la inteligencia artificial*. https://www.unesco.org/es/legal-affairs/recommendation-ethics-artificial-intelligence

UNESCO. (2025, 19 de noviembre). *UNESCO presenta el Informe de Evaluación de Preparación para la IA en Ecuador*. https://www.unesco.org/es/articles/unesco-presenta-el-informe-de-evaluacion-de-preparacion-para-la-ia-en-ecuador?hub=355

Valentini, A. (2026). Adopción y gobernanza de la IA en la educación superior de América Latina y el Caribe: Resultados de una encuesta regional. *Revista Educación Superior y Sociedad, 37*(2), 372–397. https://doi.org/10.54674/ess.v37i2.1278

Van Calster, B., McLernon, D. J., van Smeden, M., Wynants, L., & Steyerberg, E. W. (2019). Calibration: The Achilles heel of predictive analytics. *BMC Medicine, 17*, Article 230. https://doi.org/10.1186/s12916-019-1466-7

Van Schoors, R., Elen, J., Raes, A., & Depaepe, F. (2021). An overview of 25 years of research on digital personalised learning in primary and secondary education: A systematic review of conceptual and methodological trends.

British Journal of Educational Technology, 52(5), 1798–1822. https://doi.org/10.1111/bjet.13148

von Hippel, P. T., & Hofflinger, A. (2021). The data revolution comes to higher education: Identifying students at risk of dropout in Chile. *Journal of Higher Education Policy and Management, 43*(1), 2–23. https://doi.org/10.1080/1360080X.2020.1739800

Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education—Where are the educators? *International Journal of Educational Technology in Higher Education, 16*, Article 39. https://doi.org/10.1186/s41239-019-0171-0

Zúñiga-Prieto, M. A., Ortiz, M., Ulloa, M., & Jiménez, A. (2020). Applying the LALA framework for the adoption of a learning analytics tool in Latin America: Two case studies in Ecuador. *CEUR Workshop Proceedings, 2704*, 6–14. https://investigacion.ucuenca.edu.ec/es/publications/applying-the-lala-framework-for-the-adoption-of-a-learning-analyt/

ISBN: 978-9942-53-237-4



Compás
capacitación e investigación