



# MODELOS HIBRÍDOS

inteligentes para el aprendizaje personalizado  
en la **educación superior**

---

## **Autores** \_\_\_\_\_

- Elizabeth Alexandra Veloz Segura
- Verónica Teresa Veloz Segura
- Javier Alonso Veloz Segura
- Washington Raúl Fierro Saltos



E D I T O R I A L  
**UNIÓN CIENTÍFICA**

**Editorial Unión Científica, EUC**

Copyright © Editorial Unión Científica, EUC

Copyright del texto © 2026 de los autores

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

[info@editorialuc.com](mailto:info@editorialuc.com)

WhatsApp +593 98 334 4363

Licencia no comercial



**TÍTULO:** Modelos híbridos inteligentes para el aprendizaje personalizado en la educación superior

*Smart hybrid models for personalized learning in higher education*

## AUTORES

**Elizabeth Alexandra Veloz Segura**<sup>1</sup>

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

correo [eveloz@ueb.edu.ec](mailto:eveloz@ueb.edu.ec)

**Verónica Teresa Veloz Segura**<sup>1</sup>

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

correo [vveloz@ueb.edu.ec](mailto:vveloz@ueb.edu.ec)

**Javier Alonso Veloz Segura**<sup>2</sup>

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

correo [jveloz@ueb.edu.ec](mailto:jveloz@ueb.edu.ec)

**Washington Raúl Fierro Saltos**<sup>1</sup>

<https://orcid.org/0000-0001-7274-4701>

correo [wfierro@ueb.edu.ec](mailto:wfierro@ueb.edu.ec)

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

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

## CÓMO CITAR

Veloz Segura, E. A., Veloz Segura, V. T., Veloz Segura, J. A., & Fierro, W. (2026). Modelos híbridos inteligentes para el aprendizaje personalizado en la educación superior. Editorial Unión Científica. <https://doi.org/10.63804/libroseuc.5>

**Editorial Unión científica, EUC.**

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

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

**PÁGINAS:** 121.

**CIUDAD:** Ambato

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

**ISBN:** 978-9907-9552-2-4.

**DOI:** <https://doi.org/10.63804/libroseuc.5>

**PRIMERA VERSIÓN DISPONIBLE EN LÍNEA:** junio de 2026.

**Clasificación Dewey Decimal (DDC):**  
378 Educación superior.

**Clasificación THEMA:**

J	Sociedad y ciencias sociales.
JN	Educación.
JNM	Enseñanza superior, estudios avanzados
JNMT	Formación del profesorado.

ISBN: 978-9907-9552-2-4



## COMITÉ CIENTÍFICO

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

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

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

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

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

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

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

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

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

# Modelos híbridos inteligentes para el aprendizaje personalizado en la educación superior

## **Glosario de términos**

### **Accesibilidad educativa**

Condición que permite que los estudiantes participen en el proceso formativo sin barreras tecnológicas, pedagógicas, comunicacionales o institucionales.

### **Adaptación educativa**

Ajuste de recursos, actividades, tiempos, niveles de dificultad o apoyos según la evolución del aprendizaje del estudiante.

### **Agencia del estudiante**

Capacidad del estudiante para participar activamente, tomar decisiones y asumir un papel consciente en su propio proceso de aprendizaje.

### **Algoritmo**

Conjunto de instrucciones o procedimientos que permite procesar datos, identificar patrones o generar recomendaciones dentro de un sistema.

### **Analítica educativa**

Uso sistemático de datos para comprender procesos de aprendizaje y apoyar decisiones académicas, pedagógicas e institucionales.

### **Aprendizaje adaptativo**

Modalidad de aprendizaje en la que el sistema modifica contenidos, actividades o rutas según el desempeño, progreso o necesidades del estudiante.

### **Aprendizaje automático**

Técnica de inteligencia artificial que permite a un sistema identificar patrones en los datos y mejorar sus resultados sin depender únicamente de reglas explícitas.

### **Aprendizaje personalizado**

Enfoque que ajusta recursos, rutas, actividades o apoyos según necesidades, progreso y contexto del estudiante.

### **Autorregulación**

Capacidad del estudiante para planificar, monitorear y ajustar sus estrategias de aprendizaje de acuerdo con sus metas y resultados.

### **Barreras de aprendizaje**

Obstáculos pedagógicos, tecnológicos, personales, sociales o institucionales que dificultan la participación, comprensión o avance del estudiante.

### **Clasificación educativa**

Proceso mediante el cual un modelo organiza estudiantes, actividades o situaciones en categorías según determinados criterios o patrones.

### **Competencia**

Conjunto integrado de conocimientos, habilidades, actitudes y capacidades que el estudiante desarrolla para actuar en un contexto determinado.

### **Contexto académico**

Conjunto de condiciones institucionales, curriculares, tecnológicas y personales que influyen en el proceso de aprendizaje.

### **Datos educativos**

Información generada en procesos académicos, como calificaciones, participación, accesos a plataformas, evaluaciones, trayectorias y actividades.

### **Decisión automatizada**

Acción o recomendación generada por un sistema a partir del procesamiento de datos, con poca o ninguna intervención humana directa.

### **Diferenciación pedagógica**

Estrategia que permite ajustar métodos, recursos o actividades para responder a diferencias entre estudiantes o grupos.

### **Diseño instruccional**

Planificación organizada de objetivos, contenidos, actividades, recursos, evaluaciones y estrategias para favorecer el aprendizaje.

### **Equidad educativa**

Principio que busca ofrecer condiciones justas de aprendizaje, reconociendo que no todos los estudiantes requieren los mismos apoyos.

### **Ética de datos**

Conjunto de principios que orientan el uso responsable, justo, transparente y seguro de la información educativa.

### **Evaluación formativa**

Proceso de valoración continua que permite identificar avances, dificultades y necesidades de mejora durante el aprendizaje.

### **Explicabilidad**

Capacidad de comprender y comunicar por qué un sistema produce una recomendación, clasificación o predicción.

### **Gobernanza de datos**

Conjunto de políticas, roles, procedimientos y controles para usar datos educativos de manera responsable.

### **Individualización**

Ajuste de la enseñanza a características particulares de un estudiante, considerando su ritmo, desempeño, necesidades o trayectoria.

### **Inteligencia artificial educativa**

Aplicación de técnicas de inteligencia artificial para apoyar procesos de enseñanza, aprendizaje, evaluación, seguimiento y gestión académica.

### **Interoperabilidad**

Capacidad de distintos sistemas, plataformas o aplicaciones para compartir, integrar y utilizar datos de manera coherente.

### **Juicio pedagógico**

Criterio profesional del docente o equipo académico para interpretar evidencias y tomar decisiones educativas contextualizadas.

### **Mediación docente**

Intervención del docente para orientar, interpretar, acompañar y ajustar el proceso de aprendizaje con base en criterios pedagógicos.

### **Metacognición**

Capacidad del estudiante para reconocer cómo aprende, qué dificultades tiene y qué estrategias le permiten mejorar.

### **Minería de datos educativos**

Análisis de grandes volúmenes de datos académicos para identificar patrones, relaciones, tendencias o señales relevantes.

### **Modelo del estudiante**

Representación organizada de información sobre desempeño, preferencias, avance, riesgo o necesidades de apoyo.

### **Modelo híbrido inteligente**

Sistema que combina datos, reglas, conocimiento de experto, aprendizaje automático y criterios pedagógicos.

### **Ontología educativa**

Representación estructurada de conceptos, competencias, contenidos, relaciones y prerrequisitos dentro de un dominio de aprendizaje.

### **Personalización educativa**

Proceso de ajuste de la enseñanza a partir de evidencias sobre el estudiante, su contexto, su progreso y sus necesidades.

### **Predicción educativa**

Estimación anticipada de posibles resultados académicos, riesgos o necesidades de apoyo a partir del análisis de datos.

### **Privacidad de datos**

Protección de la información personal y académica del estudiante frente a usos indebidos, excesivos o no autorizados.

### **Recomendación educativa**

Sugerencia generada por un sistema, docente o equipo académico para orientar actividades, recursos, apoyos o rutas de aprendizaje.

### **Reduccionismo algorítmico**

Riesgo de interpretar la trayectoria del estudiante solo a partir de indicadores, perfiles o resultados generados por un sistema.

### **Regla pedagógica**

Criterio definido por docentes o expertos para orientar decisiones educativas dentro de un modelo o sistema inteligente.

### **Retroalimentación inteligente**

Orientación generada o apoyada por datos para mejorar decisiones del estudiante, docente o institución.

### **Riesgo académico**

Condición o señal que advierte posibles dificultades de desempeño, permanencia, participación o avance en la trayectoria formativa.

### **Ruta de aprendizaje**

Secuencia organizada de contenidos, actividades, recursos y evaluaciones que orienta el avance del estudiante.

### **Sesgo algorítmico**

Distorsión que afecta los resultados de un modelo por datos, reglas, supuestos o criterios inadecuados.

### **Sistema adaptativo**

Entorno que modifica rutas, contenidos o actividades según evidencias del proceso de aprendizaje.

### **Sistema de alerta temprana**

Mecanismo que identifica señales de riesgo académico para activar acompañamiento antes de que la dificultad se consolide.

### **Sostenibilidad institucional**

Capacidad de mantener, evaluar y mejorar una estrategia educativa en el tiempo mediante recursos, responsables y procedimientos definidos.

**Trazabilidad**

Posibilidad de seguir y documentar cómo se generó una recomendación, qué evidencia la sustentó y qué decisión se tomó.

**Transparencia algorítmica**

Condición que permite conocer de manera comprensible cómo un sistema utiliza datos y criterios para generar resultados.

**Validación del modelo**

Proceso de revisión técnica y pedagógica que permite comprobar si un modelo produce resultados pertinentes, confiables y útiles para la educación.

## Presentación

La educación superior vive una transformación que no puede explicarse solo por la llegada de nuevas tecnologías. Cambian las formas de enseñar, las trayectorias estudiantiles, las condiciones de participación y las expectativas de acompañamiento. También cambia la manera en que las instituciones producen y usan información para tomar decisiones académicas.

En ese escenario, los modelos híbridos inteligentes representan una posibilidad importante, siempre que se los entienda como sistemas de apoyo y no como sustitutos del juicio docente. Este libro analiza cómo la inteligencia artificial, la analítica educativa, el modelado del estudiante, las reglas pedagógicas y la gobernanza de datos pueden articularse para favorecer el aprendizaje personalizado en la educación superior. El interés no está en celebrar la automatización, sino en comprender bajo qué condiciones una decisión apoyada por datos puede mejorar la experiencia formativa, ampliar la equidad y fortalecer la responsabilidad institucional.

La obra se organiza en cinco secciones. Primero se revisa el contexto universitario y la diversidad estudiantil. Luego se estudian la inteligencia artificial, la analítica educativa y el modelado del estudiante. Más adelante se desarrolla la arquitectura de los modelos híbridos inteligentes.

Después se examinan sus aplicaciones pedagógicas en rutas, evaluación, retroalimentación y acompañamiento. Finalmente, se abordan permanencia, ética, privacidad, gobernanza y prospectiva.

## Índice

Glosario de términos	7
Presentación	13
Resumen	17
Abstract	18
Prólogo	19
Introducción	21
Metodología	23
<i>Delimitación del problema metodológico</i>	23
<i>Relación de componentes del modelo</i>	23
<i>Riesgos y condiciones de uso</i>	24
<i>Matriz de decisiones metodológicas</i>	24
Educación Superior, diversidad estudiantil y personalización	26
1.1. <i>Transformaciones de la Educación Superior en entornos digitales</i>	26
1.2. <i>Diversidad estudiantil, trayectorias y necesidades de aprendizaje</i>	28
1.3. <i>Concepto de aprendizaje personalizado</i>	30
1.4. <i>Personalización, inclusión y accesibilidad educativa</i>	32
1.5. <i>Competencias, autonomía y agencia del estudiante</i>	35
1.6. <i>Retos institucionales para personalizar la enseñanza</i>	38
1.7. <i>Límites pedagógicos de la personalización automatizada</i>	41
Inteligencia artificial, analítica educativa y modelado del estudiante	45
2.1. <i>Inteligencia artificial aplicada a la Educación Superior</i>	45
2.2. <i>Analítica educativa y minería de datos educativos</i>	47

2.3. Fuentes de datos para comprender el aprendizaje _____	50
2.4. Modelado del estudiante: perfiles, estados y trayectorias _____	53
2.5. Sistemas de recomendación y entornos adaptativos _____	55
2.6. Modelos predictivos para apoyo académico _____	57
2.7. Tableros de analítica y toma de decisiones académicas _____	59
Fundamentos y arquitectura de los modelos híbridos inteligentes ____	62
3.1. Concepto de modelo híbrido inteligente _____	62
3.2. Integración de enfoques simbólicos y aprendizaje automático ____	64
3.3. Arquitectura general de un modelo híbrido para personalización _	66
3.4. Ontologías, reglas pedagógicas y conocimiento experto _____	68
3.5. Algoritmos, modelos de clasificación y predicción educativa _____	71
3.6. Interoperabilidad, plataformas y ecosistemas de datos _____	74
3.7. Ciclo de vida de diseño, entrenamiento, validación y mejora _____	76
Adaptación pedagógica, evaluación formativa y retroalimentación ____	79
4.1. Diseño instruccional para aprendizaje personalizado _____	79
4.2. Rutas de aprendizaje adaptativas _____	82
4.3. Evaluación formativa mediada por datos _____	84
4.4. Retroalimentación inteligente y oportuna _____	88
4.5. Tutores inteligentes y acompañamiento académico _____	90
4.6. Adaptación de recursos, actividades y niveles de dificultad _____	92
4.7. Rol docente en sistemas de personalización inteligente _____	93
Retención académica, ética de datos y prospectiva tecnológica _____	97
5.1. Retención académica, permanencia y riesgo de abandono _____	97

---

5.2. <i>Sistemas de alerta temprana y acompañamiento institucional</i>	___ 100
5.3. <i>Ética de datos en modelos inteligentes educativos</i>	_____ 102
5.4. <i>Privacidad, transparencia, aplicabilidad y sesgos algorítmicos</i>	___ 105
5.5. <i>Gobernanza institucional de la inteligencia artificial educativa</i>	___ 107
5.6. <i>Evaluación de impacto de modelos híbridos inteligentes</i>	_____ 109
5.7. <i>Prospectiva tecnológica y futuro del aprendizaje personalizado</i>	___ 112
Conclusiones	_____ 115

## Resumen

Esta investigación aborda la necesidad de gestionar la diversidad estudiantil y las trayectorias académicas en la educación superior mediante la personalización del aprendizaje, superando los riesgos del reduccionismo algorítmico y la automatización descontextualizada que despersonalizan el proceso formativo. Mediante un enfoque de diseño instruccional aplicado y una revisión sistémica de la literatura técnica, se propone y fundamenta la arquitectura de un modelo híbrido inteligente que articula e integra de forma coherente fuentes de datos analíticos masivos procedentes de sistemas de gestión del aprendizaje (LMS), ontologías educativas, reglas pedagógicas explícitas y algoritmos de aprendizaje automático. Los resultados conceptuales demuestran que el desarrollo e implementación de entornos adaptativos y tutores inteligentes permiten modelar perfiles dinámicos de los estudiantes y estructurar rutas de aprendizaje flexibles que se ajustan de manera continua según sus niveles de logro. En este contexto, se logró diseñar sistemas de alerta temprana altamente eficientes basados en minería de datos que identifican oportunamente señales de riesgo académico y vulnerabilidad para mitigar significativamente el abandono y potenciar la retención institucional. Se concluye que la efectividad real de los modelos híbridos inteligentes no se limita a su precisión métrica o predictiva, sino que radica sustancialmente en la mediación docente activa, transparencia algorítmica, explicabilidad de las decisiones y una gobernanza ética e institucional de la información. La personalización tecnológica adquiere viabilidad y valor social únicamente cuando se consolida como un soporte orientado a fortalecer la equidad, inclusión y toma de decisiones humanas informadas dentro del ecosistema universitario.

**Palabras clave:** aprendizaje personalizado; educación superior; modelos híbridos inteligentes; rutas de aprendizaje; sistemas de alerta temprana.

---

## Abstract

This research addresses the need to manage student diversity and academic trajectories in higher education through personalized learning, overcoming the risks of algorithmic reductionism and decontextualized automation that depersonalize the educational process. Through an applied instructional design approach and a systematic review of the technical literature, this study proposes and substantiates the architecture of an intelligent hybrid model that coherently articulates and integrates massive analytical data sources from learning management systems (LMS), educational ontologies, explicit pedagogical rules, and machine learning algorithms. The conceptual results demonstrate that the development and implementation of adaptive environments and intelligent tutors make it possible to model dynamic student profiles and structure flexible learning paths that continuously adjust according to students' achievement levels. In this context, we successfully designed highly efficient early-warning systems based on data mining that promptly identify signs of academic risk and vulnerability, thereby significantly reducing dropout rates and enhancing student retention. It is concluded that the true effectiveness of intelligent hybrid models is not limited to their metric or predictive accuracy, but rather lies substantially in active faculty mediation, algorithmic transparency, decision explainability, and ethical and institutional governance of information. Technological personalization gains viability and social value only when it is established as a tool aimed at strengthening equity, inclusion, and informed human decision-making within the university ecosystem.

**Keywords:** personalized learning; higher education; intelligent hybrid models; learning pathways; early warning systems.

## Prólogo

La educación superior contemporánea se encuentra inmersa en una encrucijada histórica sin precedentes. Por un lado, las aulas universitarias, tanto físicas como virtuales, albergan una diversidad estudiantil rica y multifacética, caracterizada por una pluralidad de trayectorias académicas, ritmos de asimilación y bagajes socioeconómicos que desafían por completo los métodos tradicionales de enseñanza estandarizada. Por el otro, la irrupción vertiginosa de la inteligencia artificial y la proliferación de datos masivos dentro de los sistemas de gestión del aprendizaje (LMS) abren un abanico de posibilidades analíticas que la pedagogía clásica apenas alcanza a vislumbrar. En este escenario de transición estructural surge la presente obra, Modelos híbridos inteligentes para el aprendizaje personalizado en la educación superior, como un marco metodológico útil para investigadores, gestores educativos y docentes de nuestro tiempo.

El valor fundamental de este libro no reside meramente en su rigor técnico para explicar la arquitectura de los entornos adaptativos o la construcción de sistemas de alerta temprana frente al riesgo de desertión; radica, de manera mucho más profunda, en su firme postura filosófica y ética. A lo largo de sus páginas, se defiende con lucidez que la personalización algorítmica no debe confundirse jamás con un reduccionismo automatizado o con una despersonalización tecnocrática del estudiante. Al contrario, los modelos propuestos aquí se definen como híbridos precisamente porque combinan de forma sinérgica el poder computacional del aprendizaje automático y las ontologías de datos con las reglas pedagógicas explícitas y la indispensable mediación del juicio humano.

La obra transita magistralmente desde los cimientos contextuales de la inclusión y la equidad hasta los intrincados mecanismos que permiten modelar dinámicamente el perfil de un estudiante y sugerir rutas flexibles

de conocimiento. Sin embargo, el clímax de esta investigación se alcanza cuando confronta al lector con los imperativos éticos de la gobernanza de datos, la explicabilidad de los modelos y la transparencia algorítmica. Los autores recuerdan constantemente que una métrica predictiva carece de alma si no está al servicio de una decisión docente informada, empática y orientada a potenciar la retención institucional.

Como Editor en Jefe de la Editorial Unión Científica, me complace enormemente presentar un manuscrito de madurez conceptual y consistencia estructural. Este volumen describe el futuro de la educación universitaria; proporciona la matriz analítica, el mapa de ruta pedagógico y el marco de gobernanza necesarios para construirlo sobre una base ética y transformadora. Quedan invitados, pues, a adentrarse en una lectura rigurosa, propositiva y, por encima de todo, profundamente humana.

Ing. Carlos Luis Vásquez Freytez, PhD

Editor en Jefe

## Introducción

En el escenario contemporáneo de la educación superior, la masificación de la matrícula y la diversificación de los perfiles de ingreso han puesto en evidencia las severas limitaciones de los modelos pedagógicos homogéneos y de carácter unidireccional. Ante este panorama, la personalización del aprendizaje emerge como un imperativo fundamental para garantizar la equidad, el acceso efectivo al conocimiento y la retención institucional [1]. Sin embargo, es importante precisar el término: personalizar el aprendizaje no significa ofrecer una experiencia aislada para cada estudiante ni dejar que un sistema automatizado decida por la institución. Significa, por el contrario, reconocer diferencias relevantes, organizar apoyos oportunos y ajustar decisiones con base en evidencias interpretadas pedagógicamente. Esta distinción es neurálgica debido a que muchas promesas tecnológicas confunden sistemáticamente la personalización con una automatización descontextualizada y tecnocrática [2].

Los modelos híbridos inteligentes permiten resolver y trabajar de manera directa esa tensión estructural. Por una parte, aprovechan la capacidad analítica de los datos masivos, los algoritmos de aprendizaje automático, las reglas de inferencia y las representaciones dinámicas del estudiante dentro de las plataformas educativas. Por otra, requieren de forma estricta criterios pedagógicos explícitos, mediación docente activa, seguimiento institucional continuo y límites éticos rigurosos [3]. El aporte científico de este enfoque radica precisamente en dicha combinación sinérgica: los algoritmos ayudan a visibilizar patrones y trayectorias de aprendizaje que no siempre son evidentes a escala masiva, pero sus recomendaciones e inferencias predictivas deben poseer la propiedad de explicarse, discutirse y corregirse bajo el filtro del juicio humano [4].

Bajo esta premisa, la presente obra articula la inteligencia artificial aplicada y la teoría del diseño instruccional adaptativo a través de un estilo que es, a la vez, académico y profundamente aplicado. El manuscrito ha sido diseñado para que cada tema se desarrolle metodológicamente como una unidad de decisión independiente y estructurada. Así, en cada apartado, primero se explica y delimita el problema

pedagógico, luego se relacionan analíticamente sus componentes tecnológicos y operativos, después se presentan los riesgos asociados y las condiciones críticas de uso, y finalmente se sintetiza la aplicación práctica mediante el recurso visual que mejor corresponda al tema, ya sean glosarios, matrices de gestión o flujos de decisión.

A través de esta organización, el lector podrá seguir una progresión conceptual rigurosa y transparente, adquiriendo las herramientas conceptuales necesarias para trasladar de forma inmediata la discusión teórica hacia una práctica docente transformadora o hacia una gobernanza institucional éticamente responsable dentro del ecosistema universitario.

## Metodología

### ***Delimitación del problema metodológico***

El diseño de un sistema de aprendizaje personalizado en la educación superior enfrenta el reto de integrar fuentes de datos heterogéneas y de naturaleza dispar sin caer en el reduccionismo algorítmico. El problema metodológico central radica en la brecha existente entre los datos crudos de interacción (logs de navegación, clics y tiempos de entrega en el LMS) y el significado pedagógico de esos comportamientos. Tradicionalmente, la analítica de datos se ha limitado a ser descriptiva o reactiva. Por lo tanto, se requiere un enfoque metodológico mixto y aplicado que traduzca las variables cuantitativas del sistema en decisiones cualitativas e instruccionales válidas, garantizando la explicabilidad y la intervención docente oportuna.

### ***Relación de componentes del modelo***

La metodología de esta obra se fundamenta en el codiseño e integración analítica de cuatro componentes estructurales que operan de forma interdependiente:

- Componente de Captura y Abstracción (LMS) basado en la extracción automatizada de los registros de actividad del estudiante (frecuencia, regularidad, interacciones y calificaciones) y su transformación en indicadores normativos de rendimiento.
- Componente de representación del conocimiento (Ontología Educativa) que permita la estructuración de los contenidos conceptuales, competencias y resultados de aprendizaje del currículo mediante una red semántica que define las dependencias y jerarquías del conocimiento.
- Componente inferencial (Modelos algorítmicos e Inteligencia Artificial) para la aplicación de técnicas de aprendizaje automático (como la minería de datos educativos y la clasificación predictiva) para agrupar perfiles de estudiantes y anticipar trayectorias de riesgo académico.
- Componente heurístico (Reglas pedagógicas y mediación humana), son las definiciones de reglas explícitas del tipo *if-then* (si-entonces) codificadas por

---

expertos en diseño instruccional, las cuales condicionan el comportamiento del sistema a la validación, supervisión y juicio crítico del cuerpo docente.

### **Riesgos y condiciones de uso**

La implementación de esta metodología no está exenta de vulnerabilidades metodológicas y sesgos técnicos que deben ser previstos institucionalmente:

- El sesgo de sobreajuste (*overfitting*): debido al riesgo de que los algoritmos se ajusten excesivamente a históricos previos de estudiantes, perpetuando etiquetas o clasificando de forma errónea a nuevos perfiles que muestran comportamientos atípicos pero legítimos.
- La dependencia tecnológica absoluta que supone el peligro de automatizar la retroalimentación sin un filtro docente, provocando la despersonalización del acompañamiento educativo y la frustración del estudiante ante respuestas mecanizadas.
- Condiciones críticas de uso puesto que el modelo requiere que la recolección de datos esté condicionada al consentimiento informado explícito de los participantes. Además, ninguna recomendación de ruta adaptativa o alerta de riesgo académico puede ser vinculante o definitiva sin la revisión y firma de un tutor humano o del comité académico de la carrera.

### **Matriz de decisiones metodológicas**

Para facilitar la transferencia institucional de esta propuesta, la siguiente matriz sintetiza el flujo metodológico para la toma de decisiones pedagógicas basadas en la evidencia algorítmica (Ver Tabla 1):

**Tabla 1:** Matriz de decisiones metodológicas.

<b>Fase Metodológica</b>	<b>Fuente de Datos Primaria</b>	<b>Componente Tecnológico</b>	<b>Criterio de Control Pedagógico (Filtro Humano)</b>	<b>Resultado Esperado en el Aula</b>
1. Modelado del perfil inicial	Evaluación diagnóstica e historial académico previo.	Ontología de competencias mapas conocimiento.	de y los conocimientos de previos requeridos.	Línea base personalizada para cada estudiante.
2. Rastreo adaptativo en tiempo real	Registro de interacciones, clics y tiempos de lectura en LMS.	Algoritmos de agrupamiento ( <i>Clustering</i> dinámico).	de Ajuste del diseño instruccional según el ritmo grupal observado.	Selección automatizada de recursos complementarios alternativos.
3. Inferencia de riesgo	Patrones de inactividad prolongada y caída en evaluaciones formativas.	Modelos predictivos de minería de datos (Sistemas de Alerta Temprana).	Entrevista cualitativa tutor-estudiante para contextualizar la alerta.	Activación de tutorías académicas prioritizadas y planes de remediación.
4. Evaluación del logro	Evidencias de aprendizaje y portafolios digitales.	Matrices analíticas y rúbricas automatizadas.	Calificación final, retroalimentación cualitativa y juicio experto del docente.	Certificación de la competencia y flexibilización de la ruta futura.

## **Educación Superior, diversidad estudiantil y personalización**

Antes de hablar de algoritmos o tableros, conviene reconocer que la personalización nace de una realidad concreta: los estudiantes llegan con trayectorias, ritmos, condiciones y expectativas distintas. La tecnología puede ayudar a leer esa diversidad, pero no la reemplaza ni la agota.

### **1.1. Transformaciones de la Educación Superior en entornos digitales**

La transformación digital universitaria no se reduce a incorporar plataformas: modifica la enseñanza, la gestión y la manera de interpretar las trayectorias estudiantiles. Comprender ese cambio es indispensable antes de decidir qué datos recoger, qué modelos utilizar o qué recomendaciones ofrecer. La idea puede parecer sencilla, pero en el trabajo cotidiano exige una distinción importante.

Analizar cambios institucionales, pedagógicos y tecnológicos que modifican la enseñanza universitaria no significa agregar una herramienta a un curso ni acumular indicadores en una plataforma. La institución necesita separar tres tareas: observar una señal, interpretarla con criterio y convertirla en apoyo oportuno. En ese marco, la afirmación debe vincularse después con evidencia documental concreta antes de incorporar una cita.

El análisis de transformaciones de la educación superior en entornos digitales relaciona transformación digital, docencia mediada por tecnologías, gestión académica basada en datos e innovación pedagógica. Transformación digital abre la lectura del problema; Docencia mediada por tecnologías permite seguir su evolución; Gestión académica basada en datos introduce el contexto donde la decisión toma forma; e Innovación pedagógica obliga a precisar qué acción puede mejorar el aprendizaje. En la gestión de transformaciones de la educación superior en entornos digitales, desde una mirada de administración académica, transformaciones de la educación superior en entornos digitales debe evaluarse por las decisiones que habilita. Un dato sobre transformación digital puede orientar una ruta, pero no debería cerrar la interpretación. También puede requerir contraste con docentes, historiales, condiciones de acceso y resultados previos.

La precaución básica en transformaciones de la educación superior en entornos digitales consiste en no confundir señal con explicación suficiente. El riesgo aparece cuando transformación digital se convierte en etiqueta e innovación pedagógica se transforma en respuesta automática. Por eso conviene trabajar con criterios explícitos y con mecanismos de corrección, no con clasificaciones cerradas. En el trabajo cotidiano, este apartado retoma el problema anterior y lo vuelve más operativo.

También anticipa diversidad estudiantil, trayectorias y necesidades de aprendizaje, porque cada evidencia debe traducirse en criterios comprensibles para docentes y responsables académicos. Ese recorrido se sintetiza en la Figura 1, pensada para mostrar el flujo entre datos, interpretación y decisión.



**Figura 1.** Flujo de decisión para transformaciones en entornos digitales.

En transformaciones de la Educación Superior en entornos digitales, el gráfico puede mostrar un recorrido que comienza en transformación digital, incorpora los demás componentes del tema como criterios de interpretación y termina en innovación pedagógica como decisión revisable. Conviene ubicar debajo una franja de mediación docente, seguimiento institucional y retroalimentación.

La figura se justifica porque transformaciones de la Educación Superior en entornos digitales describe un proceso, una arquitectura o una relación dinámica que se comprende mejor visualmente.

En transformaciones de la Educación Superior en entornos digitales, con este marco, en síntesis, transformaciones de la Educación Superior en entornos digitales aporta una condición de continuidad: permite pasar de la explicación conceptual a una decisión educativa que pueda discutirse, aplicarse y revisarse. Desde aquí se abre el

---

paso hacia diversidad estudiantil, trayectorias y necesidades de aprendizaje, donde esa condición se examina con otro grado de detalle.

### **1.2. Diversidad estudiantil, trayectorias y necesidades de aprendizaje**

En diversidad estudiantil, trayectorias y necesidades de aprendizaje, la pregunta inicial es qué cambia para el estudiante cuando el concepto se lleva a una decisión real. En términos operativos, el punto decisivo está en cómo se convierte la información en acción. Examinar heterogeneidad de perfiles, ritmos, condiciones y expectativas estudiantiles exige separar la promesa tecnológica de la decisión educativa. Los datos pueden ampliar la mirada institucional, pero solo adquieren sentido cuando ayudan a comprender una necesidad, elegir una acción y revisar sus efectos. Esta lectura queda como formulación de trabajo hasta que se vincule con una fuente específica y verificable.

Al analizar diversidad estudiantil, trayectorias y necesidades de aprendizaje, para avanzar, para que la exposición avance, conviene leer juntos perfil de ingreso, trayectoria académica, condiciones de participación y necesidades de apoyo. Perfil de ingreso no tiene valor aislado si no se relaciona con trayectoria académica; Condiciones de participación muestra las condiciones de uso; y Necesidades de apoyo convierte la información en una posibilidad de intervención.

En la práctica institucional, diversidad estudiantil exige reconocer que trayectorias y necesidades de aprendizaje, para los equipos de gestión, diversidad estudiantil, trayectorias y necesidades de aprendizaje plantea una exigencia concreta: transformar información dispersa en criterios compartidos. Si cada área interpreta perfil de ingreso de manera distinta, la respuesta vinculada con necesidades de apoyo se vuelve irregular y difícil de evaluar. La Tabla 2 separa la señal disponible, la lectura académica y el uso pedagógico posible.

**Tabla 2.** Criterios aplicados para diversidad estudiantil, trayectorias y necesidades de aprendizaje.

Elemento	Lectura aplicada	Uso en el modelo
Perfil de ingreso	Se revisa cómo perfil de ingreso se conecta con trayectoria académica.	La decisión educativa gana sentido cuando esa relación se interpreta con contexto.
Trayectoria académica	Se usa trayectoria académica como señal inicial, contrastada con condiciones de participación.	Evita que el indicador se lea de manera aislada al tomar la decisión.
Condiciones de participación	Se observa qué ocurre cuando condiciones de participación aparece asociado con necesidades de apoyo.	Permite precisar qué cambia en la intervención pedagógica.
Necesidades de apoyo	Se observa la tensión entre necesidades de apoyo y perfil de ingreso.	Define si el modelo informa una acción concreta o solo produce una clasificación.

Esta lectura requiere prudencia: diversidad estudiantil, trayectorias y necesidades de aprendizaje orienta decisiones, pero no reemplaza el juicio pedagógico.

El límite más delicado surge cuando la institución confunde predicción con destino. Una señal sobre perfil de ingreso puede advertir una dificultad, pero no autoriza a reducir la trayectoria del estudiante a una clasificación.

El razonamiento pasa ahora de la comprensión a la acción. Lo discutido aquí prepara concepto de aprendizaje personalizado, donde la decisión necesita nuevos criterios y otra escala de análisis.

En diversidad estudiantil, trayectorias y necesidades de aprendizaje, desde esta perspectiva, el aprendizaje principal del apartado es que diversidad estudiantil, trayectorias y necesidades de aprendizaje solo tiene valor cuando mejora una decisión concreta y deja trazabilidad sobre sus efectos. El apartado siguiente, dedicado a concepto de aprendizaje personalizado, retoma esta misma preocupación desde una dimensión complementaria.

### 1.3. Concepto de aprendizaje personalizado

Diversidad estudiantil, trayectorias y necesidades de aprendizaje preparó el terreno para esta discusión. Ahora, concepto de aprendizaje personalizado permite observar el mismo problema desde otro nivel de decisión.

En concepto de aprendizaje personalizado, la definición importa menos que la decisión educativa que permite ordenar. También conviene mirar el tema desde la organización que debe sostenerlo. Distinguir personalización, individualización, diferenciación y adaptación educativa debe leerse como un problema de gestión pedagógica. La detección gana valor cuando permite definir quién actúa, con qué información y bajo qué límite. Los trabajos de Yuyón y Sueldo y Chat ti y Muslime permiten ubicar esa relación entre evidencia y acción [5], [6].

Al analizar concepto de aprendizaje personalizado, la lectura gana claridad cuando la secuencia conceptual parte de personalización, pasa por individualización y diferenciación, y desemboca en adaptación. Esa progresión evita que el apartado sea una enumeración y permite leer cada componente como parte de una decisión educativa mayor.

Como se muestra en la Tabla 3, el paso decisivo no está en nombrar el componente, sino en definir qué decisión permite tomar.

**Tabla 3.** Criterios aplicados para concepto de aprendizaje personalizado.

Componente	Pregunta pedagógica	Decisión que permite tomar
Personalización	¿Qué necesita el estudiante para avanzar de acuerdo con su trayectoria, ritmo y contexto?	Definir si corresponde ajustar recursos, actividades, acompañamiento o ruta de aprendizaje.
Individualización	¿Qué características particulares del estudiante deben considerarse antes de intervenir?	Precisar si la respuesta debe dirigirse a un estudiante específico y no al grupo completo.
Diferenciación	¿Qué diferencias entre estudiantes o grupos requieren estrategias pedagógicas distintas?	Organizar apoyos, actividades o niveles de complejidad según necesidades comunes.
Adaptación	¿Qué debe modificarse durante el proceso cuando la evidencia muestra avances, dificultades o cambios?	Ajustar la secuencia, el ritmo, la retroalimentación o el nivel de dificultad según la evolución del aprendizaje.

La matriz permite revisar si la institución sabe qué observa, para qué lo observa y qué tipo de respuesta puede sostener a partir de esa información. En este sentido, el aprendizaje personalizado no debe entenderse únicamente como una estrategia centrada en ajustar contenidos o actividades para cada estudiante, sino como una forma de organizar decisiones pedagógicas con base en evidencias.

La utilidad de la personalización depende de que la información disponible pueda transformarse en acciones pertinentes, oportunas y revisables. Al llevar concepto de aprendizaje personalizado a la práctica, el enfoque gerencial ayuda a ordenar responsabilidades. Primero se define qué observar; luego se interpreta individualización; finalmente se revisa si la acción vinculada con adaptación tuvo efecto.

El punto delicado en concepto de aprendizaje personalizado está en conservar margen para revisar la recomendación del sistema. También existe un riesgo de exceso de confianza. Si el sistema presenta adaptación como solución evidente, puede ocultar condiciones que no están en los datos y que solo aparecen mediante diálogo pedagógico. Este punto conecta hacia adelante porque ninguna arquitectura inteligente opera en el vacío. Lo que se define aquí como criterio volverá a aparecer en personalización, inclusión y accesibilidad educativa como condición de aplicación.

Desde esta perspectiva, la personalización requiere una lectura integrada de las trayectorias estudiantiles. No basta con reconocer que los estudiantes aprenden de manera diferente; también es necesario identificar qué factores explican esas diferencias, qué apoyos resultan adecuados y qué actores institucionales deben intervenir. Por ello, la individualización, la diferenciación y la adaptación no funcionan como categorías aisladas, sino como niveles sucesivos de decisión. La individualización permite reconocer características particulares del estudiante; la diferenciación orienta ajustes pedagógicos para grupos o perfiles con necesidades similares; y la adaptación permite modificar recursos, ritmos, actividades o apoyos de acuerdo con la evolución del proceso formativo.

Este enfoque también exige reconocer que toda decisión basada en datos tiene límites. Los sistemas inteligentes pueden identificar patrones, alertar sobre riesgos o

sugerir rutas de aprendizaje, pero no sustituyen la interpretación pedagógica. La información producida por el sistema debe ser contrastada con el contexto del estudiante, la experiencia docente y las condiciones institucionales. De lo contrario, existe el riesgo de convertir la personalización en una clasificación automática, donde el estudiante queda reducido a indicadores de desempeño, participación o avance.

Por esa razón, el aprendizaje personalizado debe conservar un componente deliberativo. Las recomendaciones generadas por un modelo híbrido deben ser entendidas como insumos para la toma de decisiones, no como respuestas definitivas. El docente, el tutor o el equipo académico mantienen un papel central al interpretar la información, validar la pertinencia de la intervención y ajustar la acción cuando las condiciones del estudiante cambian. Esta relación entre sistema y criterio humano es fundamental para evitar decisiones rígidas o poco sensibles a factores que no siempre aparecen en los datos.

En concepto de aprendizaje personalizado, visto así, la idea que queda es prudente: el modelo híbrido ayuda si amplía la comprensión del aprendizaje, no si reemplaza el juicio académico por una clasificación rápida. Su valor está en fortalecer la capacidad institucional para observar trayectorias, anticipar necesidades, proponer apoyos y evaluar si las acciones implementadas producen mejoras reales. Con esta base, personalización, inclusión y accesibilidad educativa pueden analizarse sin perder la relación entre datos, criterio pedagógico y acción institucional.

#### **1.4. Personalización, inclusión y accesibilidad educativa**

El recorrido no cambia de dirección; se vuelve más específico. Lo trabajado en concepto de aprendizaje personalizado encuentra aquí, en personalización, inclusión y accesibilidad educativa, una aplicación más concreta.

Para leer personalización, inclusión y accesibilidad educativa con provecho, conviene pasar pronto de la categoría general a la situación que debe resolverse. Sin embargo, el valor del enfoque no aparece en la técnica aislada. Relacionar personalización con equidad, accesibilidad y reducción de barreras plantea una pregunta de fondo: que puede hacer mejor la institución cuando comprende el aprendizaje con mayor detalle. La respuesta no está en automatizar la decisión, sino en precisar que información

ayuda, que límite tiene y como se traduce en apoyo. Cualquier referencia que se incorpore aquí debe mostrar de forma directa esa relación entre información, límite y apoyo. En la Tabla 4, la lectura operativa queda concentrada en elementos que pueden discutirse antes de intervenir.

**Tabla 4.** Criterios aplicados para personalización, inclusión y accesibilidad educativa.

<b>Criterio inclusivo</b>	<b>Barrera que permite identificar</b>	<b>Apoyo institucional posible</b>
Equidad	Diferencias en las condiciones de acceso, participación o avance que pueden afectar el aprendizaje.	Revisar si el estudiante necesita apoyo académico, tecnológico, tutorial o de acompañamiento institucional.
Accesibilidad	Dificultades para utilizar recursos, comprender materiales, participar en actividades o cumplir procesos formativos.	Ajustar formatos, tiempos, recursos, canales de comunicación o condiciones de participación.
Apoyos diferenciados	Necesidades que no pueden resolverse con una respuesta uniforme para todos los estudiantes.	Definir apoyos específicos según la situación: refuerzo, tutoría, flexibilización, recursos alternativos o seguimiento.
Barreras de aprendizaje	Obstáculos pedagógicos, de tecnológicos, institucionales o personales que limitan la trayectoria del estudiante.	Determinar si corresponde intervenir, adaptar la estrategia o mantener seguimiento antes de tomar una decisión mayor.

En este apartado, la personalización adquiere sentido cuando se vincula con condiciones reales de inclusión y accesibilidad. No se trata únicamente de identificar diferencias entre estudiantes, sino de reconocer qué barreras afectan su participación, su permanencia y su avance dentro del proceso formativo.

Permite preguntar si todos los estudiantes cuentan con condiciones razonables para aprender y si las diferencias observadas responden a necesidades individuales, limitaciones del entorno, falta de apoyos o dificultades de acceso a recursos. Por ello, la accesibilidad no debe reducirse al uso de herramientas tecnológicas o a la disponibilidad de materiales digitales.

Al analizar personalización, inclusión y accesibilidad educativa, el desarrollo del tema exige observar que los cuatro componentes del apartado cumplen funciones distintas. Equidad orienta el diagnóstico inicial; Accesibilidad ayuda a reconocer

cambios; Apoyos diferenciados protege la lectura contextual; y Barreras de aprendizaje permite cerrar el circuito con una respuesta formativa.

Desde la coordinación académica, personalización se vuelve manejable cuando inclusión y accesibilidad educativa, en una institución, personalización, inclusión y accesibilidad educativa no puede depender de intuiciones individuales ni de cálculos opacos. Necesita procedimientos claros, registros simples y espacios donde la evidencia se discuta antes de convertirse en decisión.

El riesgo, en personalización, inclusión y accesibilidad educativa, aparece cuando la institución actúa con más rapidez que criterio. Una lectura responsable debe reconocer que apoyos diferenciados puede alterar el significado de cualquier indicador. Dos estudiantes con la misma señal pueden necesitar respuestas distintas. El argumento avanza así de manera gradual: primero se delimita el problema, luego se precisan los componentes y después se abre el camino hacia competencias, autonomía y agencia del estudiante.

Los apoyos diferenciados cumplen una función central porque evitan respuestas uniformes ante situaciones que parecen similares. Dos estudiantes pueden mostrar bajo rendimiento, poca participación o retraso en actividades, pero las causas pueden ser distintas. Uno puede requerir acompañamiento académico, otro puede necesitar ajustes de acceso, flexibilidad temporal, recursos alternativos o seguimiento tutorial. Por eso, la información generada por el modelo debe interpretarse con prudencia y no convertirse de manera automática en una intervención.

En este sentido, las barreras de aprendizaje permiten cerrar el análisis porque obligan a desplazar la mirada desde el déficit del estudiante hacia las condiciones que dificultan su proceso. Una institución que personaliza de forma responsable no pregunta solamente qué le falta al estudiante, sino qué puede ajustar el entorno académico para favorecer mejores oportunidades de aprendizaje. Esta diferencia es importante porque impide que la personalización se convierta en etiquetamiento o en una asignación rígida de perfiles.

El modelo híbrido, por tanto, debe servir como apoyo para organizar evidencias, detectar señales relevantes y proponer rutas de atención, pero siempre dentro de un

marco pedagógico explicable. La recomendación debe poder justificarse con información clara, debe admitir revisión docente y debe considerar las condiciones particulares del estudiante. Si una decisión no puede explicarse, corregirse o contextualizarse, entonces pierde valor educativo, aunque provenga de un sistema técnicamente avanzado.

En personalización, inclusión y accesibilidad educativa, el punto que conviene retener es este: toda personalización debe poder explicarse al estudiante, al docente y a la institución. Solo así la información se convierte en apoyo y no en simple clasificación. El siguiente tema, competencias, autonomía y agencia del estudiante, permite continuar la secuencia y revisar cómo estas decisiones también deben fortalecer la participación activa del estudiante en su propio proceso de aprendizaje.

### **1.5. Competencias, autonomía y agencia del estudiante**

Para mantener el hilo del libro, competencias, autonomía y agencia del estudiante debe leerse como continuación de personalización, inclusión y accesibilidad educativa. La diferencia está en el tipo de evidencia y en la responsabilidad que cada decisión activa.

Competencias, autonomía y agencia del estudiante gana claridad cuando se lo vincula con una decisión docente, institucional o de acompañamiento. La discusión debe volver una y otra vez al estudiante y a la decisión educativa. Estudiar cómo la personalización puede fortalecer autorregulación, participación y toma de decisiones requiere una lectura menos instrumental de la tecnología. Un sistema puede ordenar datos y sugerir rutas, aunque la pertinencia de esas rutas depende de su relación con objetivos, contexto y mediación docente. Esa cautela requiere una cita solo cuando el documento fuente trate de manera explícita la relación entre contexto, mediación y ruta, en la Tabla 5 se muestran los criterios.

**Tabla 5.** Criterios aplicados para competencias, autonomía y agencia del estudiante.

<b>Dimensión estudiante</b>	<b>del Evidencia observable</b>	<b>Acción de acompañamiento</b>
Autorregulación	El estudiante planifica, cumple actividades, revisa retroalimentaciones y ajusta sus estrategias de aprendizaje.	Orientar hábitos de estudio, seguimiento de metas, organización del tiempo y revisión de avances.

Dimensión del estudiante	Evidencia observable	Acción de acompañamiento
Agencia	El estudiante toma decisiones, solicita apoyo, propone rutas o participa activamente en su proceso formativo.	Abrir espacios de decisión guiada para que el estudiante pueda elegir recursos, actividades o formas de mejora.
Participación	El estudiante interactúa con docentes, compañeros, recursos, actividades y espacios de aprendizaje.	Identificar si requiere motivación, acompañamiento, ajustes de acceso o estrategias de integración académica.
Metacognición	El estudiante reconoce que comprende, qué le cuesta y qué estrategias le ayudan a aprender mejor.	Promover reflexión sobre el propio aprendizaje mediante retroalimentación, autoevaluación y revisión de errores.

El cuadro ofrece una lectura breve, pero suficiente para discutir responsabilidades; si una fila no puede explicarse, la decisión asociada todavía no está madura. Esta observación es importante porque las competencias, la autonomía y la agencia del estudiante no pueden reducirse a indicadores de actividad dentro de una plataforma. Su valor educativo aparece cuando esos datos permiten comprender cómo el estudiante participa, regula su aprendizaje, toma decisiones y reconoce sus propios avances o dificultades. Al analizar competencias, autonomía y agencia del estudiante, la exposición se ordena mejor si leídos en conjunto, autorregulación, agencia, participación y metacognición forman una cadena de decisión.

Primero aparece una señal, luego se interpreta su trayectoria, después se revisa el contexto y finalmente se define una acción que pueda ser observada y corregida. En la gestión de competencias, autonomía y agencia del estudiante, la utilidad del modelo se mide en la coordinación que produce. Cuando docencia, bienestar, tecnología y dirección curricular trabajan con el mismo criterio, autorregulación deja de ser un dato suelto y se vuelve parte de una estrategia.

La precaución básica en competencias, autonomía y agencia del estudiante consiste en no confundir señal con explicación suficiente. El problema no está en usar datos, sino en usarlos sin contexto. Cuando agencia se interpreta sin mediación, el modelo puede producir decisiones ordenadas, aunque pedagógicamente pobres. La relación con el tema siguiente es práctica. Si competencias, autonomía y agencia del

---

estudiante no se resuelve con claridad, retos institucionales para personalizar la enseñanza quedara apoyado sobre supuestos frágiles.

En este sentido, la autorregulación debe entenderse como una capacidad que se construye progresivamente. No basta con observar si el estudiante entrega tareas, revisa materiales o cumple actividades. También es necesario analizar si logra planificar su trabajo, ajustar sus estrategias, identificar errores y buscar apoyo cuando lo necesita. Por ello, la autorregulación no debe ser interpretada como una responsabilidad exclusivamente individual, sino como una competencia que requiere acompañamiento, orientación y condiciones institucionales adecuadas.

La agencia del estudiante amplía esta lectura porque permite observar su capacidad para intervenir activamente en su propio proceso formativo. Un estudiante con agencia no solo responde a instrucciones, sino que participa, decide, pregunta, propone y evalúa sus propias rutas de aprendizaje.

Sin embargo, esta agencia no surge de manera automática por el uso de tecnología, requiere espacios pedagógicos donde el estudiante pueda comprender las recomendaciones del sistema, discutir las con el docente y tomar decisiones informadas sobre su trayectoria.

La participación, por su parte, debe leerse con cautela. Una alta participación no siempre significa aprendizaje profundo, así como una baja participación no siempre indica desinterés. Puede estar asociada a dificultades de acceso, falta de claridad en las instrucciones, problemas de tiempo, inseguridad académica o barreras personales e institucionales. Por eso, el modelo híbrido debe evitar interpretaciones lineales y permitir que la información sea contrastada con otros elementos del contexto.

La metacognición cierra este conjunto porque permite observar si el estudiante comprende cómo aprende. Cuando el estudiante reconoce sus fortalezas, identifica sus dificultades y evalúa la eficacia de sus estrategias, la personalización deja de ser una acción externa y se convierte en una oportunidad para fortalecer su autonomía. En este punto, el modelo no solo debe recomendar actividades, sino también generar información comprensible que ayude al estudiante a reflexionar sobre su propio proceso.

Por lo tanto, competencias, autonomía y agencia del estudiante fortalecen la obra porque conectan datos, mediación y seguimiento dentro de una misma lógica de responsabilidad. El modelo híbrido adquiere valor cuando no solo organiza información sobre el estudiante, sino cuando contribuye a formar estudiantes más conscientes, participativos y capaces de tomar decisiones sobre su aprendizaje. A partir de este punto, retos institucionales para personalizar la enseñanza aparece como una consecuencia natural del argumento, porque ninguna estrategia de personalización puede sostenerse si la institución no define condiciones, responsabilidades y mecanismos de acompañamiento claros.

### 1.6. Retos institucionales para personalizar la enseñanza

El paso desde competencias, autonomía y agencia del estudiante hacia retos institucionales para personalizar la enseñanza permite afinar el argumento. Ya no se trata solo de reconocer el problema, sino de establecer como puede gestionarse.

Antes de convertir retos institucionales para personalizar la enseñanza en procedimiento, hace falta precisar qué problema educativo permite mirar con más cuidado. Esta lectura ayuda a evitar una interpretación demasiado instrumental del problema. Abordar infraestructura, cultura docente, datos, gestión académica y sostenibilidad se vuelve útil cuando conecta información disponible con decisiones que alguien puede explicar. Si la institución no sabe por qué actúa, el modelo pierde valor pedagógico, aunque funcione técnicamente. Por eso, du Playo, Casteleijn y Franzsen y Villegas-Ch y Garcia-Ortiz ayudan a mantener un equilibrio entre análisis, intervención y responsabilidad [5], [7]. En la Tabla 6 se resumen los criterios aplicados.

**Tabla 6.** Criterios aplicados para retos institucionales para personalizar la enseñanza.

Reto institucional	Condición que debe revisarse	Decisión de gestión
Infraestructura	Disponibilidad de plataformas, conectividad, recursos digitales y acceso para estudiantes y docentes.	Determinar si la institución cuenta con condiciones técnicas suficientes para implementar personalización sin generar nuevas brechas.
Formación docente	Capacidad del profesorado para interpretar datos, pedagógicos y contextualizadas.	Definir procesos de capacitación docente y criterios comunes para usar el modelo de manera responsable.

<b>Reto institucional</b>	<b>Condición que debe revisarse</b>	<b>Decisión de gestión</b>
Gestión de datos	Calidad, actualización, integración, protección y uso pedagógico de la información académica disponible.	Establecer procedimientos para recolectar, revisar, interpretar y utilizar datos antes de activar recomendaciones o intervenciones.
Sostenibilidad	Recursos, responsables, protocolos, evaluación continua y capacidad institucional para mantener el modelo en el tiempo.	Decidir si la estrategia puede institucionalizarse, ajustarse progresivamente o limitarse a una aplicación piloto.

La organización del cuadro desplaza la pregunta desde el significado del concepto hacia lo que cambia cuando se incorpora al diseño educativo. En este apartado, los retos institucionales dejan de ser una lista de dificultades generales y se convierten en condiciones concretas para que la personalización pueda aplicarse con responsabilidad. La infraestructura, la formación docente, la gestión de datos y la sostenibilidad no deben analizarse por separado, porque cada una afecta la capacidad real de la institución para transformar información en decisiones pedagógicas.

Al analizar retos institucionales para personalizar la enseñanza, el argumento se vuelve más concreto cuando no todos los elementos pesan igual en cada institución.

A veces infraestructura ofrece la señal principal; en otros casos, gestión de datos explica mejor la dificultad. Lo importante es que sostenibilidad no sea una reacción automática, sino una respuesta fundada. Cuando retos institucionales para personalizar la enseñanza pasa al plano institucional, administrar este proceso implica aceptar que la información educativa siempre es incompleta. Por eso, la recomendación del sistema debe abrir una conversación sobre gestión de datos, no reemplazarla.

Retos institucionales para personalizar la enseñanza exige una cautela sencilla: ningún dato debe cerrar por sí solo la interpretación. La automatización resulta útil mientras conserve puntos de revisión. Si una recomendación sobre sostenibilidad no puede explicarse, discutirse o corregirse, el sistema pierde legitimidad educativa.

La infraestructura constituye una condición inicial, pero no suficiente. Contar con plataformas, conectividad, repositorios o sistemas de seguimiento no garantiza una

enseñanza personalizada. Su valor depende de la manera en que estos recursos se integran a los procesos académicos. Una institución puede disponer de tecnología, pero si los docentes no comprenden cómo interpretar los datos o si los estudiantes no acceden de forma equitativa a los recursos, la personalización queda reducida a una promesa técnica.

Por ello, la formación docente ocupa un lugar central. Personalizar la enseñanza exige que el profesorado pueda leer evidencias, reconocer patrones, identificar límites de la información y tomar decisiones contextualizadas. Esta formación no debe limitarse al uso operativo de herramientas digitales; también debe incluir criterios pedagógicos, éticos y metodológicos para interpretar recomendaciones, revisar alertas y decidir cuándo una intervención es pertinente. El docente no desaparece ante el modelo, sino que se vuelve más necesario como mediador de la información.

La gestión de datos, a su vez, define la calidad de las decisiones posibles. Si los datos están incompletos, desactualizados, dispersos o mal interpretados, el sistema puede producir recomendaciones aparentemente precisas, pero pedagógicamente débiles. Por eso, la institución debe establecer procedimientos claros para recolectar, organizar, proteger, revisar y utilizar la información educativa. La personalización responsable no depende solo de tener datos, sino de saber qué datos son relevantes, cómo se obtienen, quién los interpreta y con qué propósito se usan.

La sostenibilidad permite cerrar esta lectura institucional. Una estrategia de personalización no puede depender de esfuerzos aislados, de docentes motivados individualmente o de proyectos temporales sin continuidad. Requiere planificación, recursos, seguimiento, evaluación y mejora progresiva.

También exige que la institución pueda sostener los procesos de acompañamiento, actualización tecnológica, capacitación docente y revisión pedagógica de las decisiones automatizadas o semiautomatizadas.

En retos institucionales para personalizar la enseñanza, el cierre operativo es claro: una decisión personalizada necesita evidencia suficiente, criterio pedagógico y posibilidad de corrección. Si cualquiera de estos elementos falta, la personalización

corre el riesgo de convertirse en una clasificación rápida, una intervención débil o una respuesta difícil de justificar. Por el contrario, cuando la institución articula infraestructura, formación docente, gestión de datos y sostenibilidad, el modelo híbrido puede convertirse en una herramienta de apoyo para mejorar la toma de decisiones académicas.

La discusión queda preparada para avanzar hacia los límites pedagógicos de la personalización automatizada. Este paso es necesario porque, una vez reconocidas las condiciones institucionales, corresponde analizar hasta dónde puede llegar la automatización y en qué momentos debe prevalecer la interpretación pedagógica. De este modo, el capítulo conserva su hilo argumental: los datos ayudan a observar mejor, pero la decisión educativa exige mediación, responsabilidad y revisión constante.

### **1.7. Límites pedagógicos de la personalización automatizada**

La sección avanza de manera acumulativa. Retos institucionales para personalizar la enseñanza dejó planteado un límite; límites pedagógicos de la personalización automatizada examina una forma de responderlo.

Cuando se examina límites pedagógicos de la personalización automatizada, conviene partir de una situación educativa concreta antes que de una definición general. El asunto se vuelve más claro cuando se observa el proceso completo. Revisar riesgos de automatizar decisiones educativas sin mediación docente no puede reducirse a una operación técnica. Implica reconocer condiciones de aprendizaje, valorar evidencias parciales y decidir apoyos que no cierren la trayectoria del estudiante de antemano. Las referencias de Guzmán-Valenzuela et al. permiten sostener esa interpretación. La Tabla 7 permite llevar la discusión a un plano más concreto sin perder la relación entre criterio pedagógico y uso institucional.

**Tabla 7.** Criterios aplicados para límites pedagógicos de la personalización automatizada.

Riesgo pedagógico	Pregunta de control	Criterio antes de intervenir
Reduccionismo algorítmico	¿El modelo está reduciendo la trayectoria del estudiante a un indicador, perfil o alerta?	Revisar otras evidencias antes de aceptar la recomendación como válida.

Riesgo pedagógico	Pregunta de control	Criterio antes de intervenir
Contexto pedagógico	¿La recomendación considera la asignatura, la modalidad, el nivel de dificultad y las condiciones del estudiante?	Contrastar la señal con información académica, docente e institucional.
Mediación docente	¿Existe intervención docente para interpretar, ajustar o corregir la recomendación del sistema?	Mantener la decisión bajo revisión pedagógica y no delegarla completamente al modelo.
Decisión automatizada	¿La acción sugerida puede explicarse, discutirse y modificarse si el contexto cambia?	Aplicar la recomendación solo si permite

La matriz opera como control de coherencia: cada elemento debe tener una evidencia asociada, una interpretación posible y una consecuencia formativa razonable. Esta relación es necesaria porque los límites pedagógicos de la personalización automatizada no se encuentran únicamente en la tecnología, sino en la forma en que la institución interpreta y utiliza sus resultados. Un sistema puede procesar grandes volúmenes de información, identificar patrones y sugerir acciones, pero esa capacidad no garantiza por sí misma una decisión educativa pertinente.

Al analizar límites pedagógicos de la personalización automatizada, la relación interna del tema muestra que el apartado gana fuerza cuando reduccionismo algorítmico, contexto pedagógico, mediación docente y decisión automatizada se leen como partes de un mismo proceso. Cada elemento aporta una pregunta distinta, y la suma de esas preguntas ayuda a construir una intervención más responsable.

Cuando límites pedagógicos de la personalización automatizada entra en la gestión cotidiana, conviene reconocer que el valor institucional aparece cuando la lectura de reduccionismo algorítmico ayuda a actuar con oportunidad. Esa oportunidad, sin embargo, necesita controles: trazabilidad, responsables definidos y revisión periódica de efectos. El punto delicado es que límites pedagógicos de la personalización automatizada puede ayudar a decidir y, al mismo tiempo, empobrecer la interpretación si se aplica sin contraste. Conviene evitar una lectura determinista. reduccionismo algorítmico puede orientar una decisión, pero la acción institucional debe considerar historia académica, condiciones materiales y percepción del estudiante.

El reduccionismo algorítmico aparece cuando la complejidad del aprendizaje se traduce en indicadores demasiado estrechos. El rendimiento, la asistencia, la

participación en plataformas o el cumplimiento de actividades pueden ofrecer señales útiles, pero no explican por completo la trayectoria de un estudiante. Si esos datos se interpretan sin contexto, el modelo puede producir recomendaciones rápidas, aunque insuficientes. Por ello, toda alerta o sugerencia automatizada debe abrir una pregunta pedagógica antes de convertirse en intervención.

El contexto pedagógico permite ampliar esa lectura. Cada estudiante aprende dentro de condiciones concretas: historia académica, acceso a recursos, acompañamiento familiar, carga laboral, situación emocional, competencias previas y relación con el entorno institucional. Muchos de estos factores no siempre aparecen en los datos disponibles. Por esta razón, la personalización automatizada debe ser entendida como un apoyo para la interpretación, no como una sustitución del análisis docente o institucional.

La mediación docente cumple aquí una función decisiva, el docente no solo valida o corrige una recomendación; también aporta conocimiento situado sobre el proceso de aprendizaje, las dificultades del grupo, las condiciones de la asignatura y las posibilidades reales de intervención.

Sin esa mediación, la decisión automatizada puede volverse rígida, impersonal o poco sensible a circunstancias que modifican el significado de los datos. La recomendación técnica necesita ser contrastada con criterio pedagógico para conservar legitimidad educativa.

La decisión automatizada, por tanto, debe mantenerse dentro de un marco de revisión. Esto implica que la institución defina quién interpreta la recomendación, qué evidencias la sostienen, qué margen existe para corregirla y cómo se evalúan sus efectos. Una intervención personalizada no debe cerrar la trayectoria del estudiante ni anticipar de manera definitiva sus posibilidades de aprendizaje. Debe funcionar como una orientación flexible, revisable y explicable.

En límites pedagógicos de la personalización automatizada, el aporte del apartado puede resumirse así: la sofisticación técnica no compensa una lectura pobre del contexto educativo. Un modelo puede ser preciso en términos estadísticos y, al mismo tiempo, limitado en términos pedagógicos si no incorpora mediación,

deliberación y responsabilidad institucional. Por eso, el uso de la personalización automatizada exige criterios previos, controles claros y espacios de revisión que protejan al estudiante de decisiones reduccionistas.

El lector puede pasar a inteligencia artificial aplicada a la Educación Superior con una pregunta más precisa sobre el uso responsable de la personalización. Ya no se trata solo de identificar qué puede hacer la tecnología, sino de establecer bajo qué condiciones sus resultados pueden convertirse en apoyo educativo legítimo. De este modo, el libro avanza desde el problema pedagógico hacia las tecnologías que permiten observarlo, sin perder de vista que toda decisión formativa debe conservar contexto, mediación y posibilidad de corrección.

## **Inteligencia artificial, analítica educativa y modelado del estudiante**

La segunda sección desplaza el foco hacia las tecnologías que permiten observar, modelar y apoyar el aprendizaje. La inteligencia artificial, la analítica educativa y la minería de datos no son equivalentes; cada una aporta capacidades distintas y también riesgos distintos. Por eso, su valor depende de la pregunta educativa que organiza el uso de los datos.

### **2.1. Inteligencia artificial aplicada a la Educación Superior**

Antes de entrar en inteligencia artificial aplicada a la Educación Superior, conviene recordar el punto previo: límites pedagógicos de la personalización automatizada. Esa referencia evita que el nuevo tema aparezca como bloque aislado.

Previo a convertir inteligencia artificial aplicada a la Educación Superior en procedimiento, hace falta precisar qué problema educativo permite mirar con más cuidado. Desde la gestión académica, la pregunta no es solo que puede medir el sistema. Presentar usos, alcances y límites de la IA en enseñanza, aprendizaje y gestión académica introduce un criterio práctico para la Educación Superior: usar tecnología solo cuando mejora la comprensión del proceso formativo. Los indicadores, por sí solos, no enseñan; orientan cuando se insertan en una decisión pedagógica clara. Esa perspectiva dialoga con Zawacki-Richter et al. y Guzmán-Valenzuela et al. [8], [9].

Al analizar inteligencia artificial aplicada a la Educación Superior, para evitar una lectura fragmentada, en lugar de tratar automatización, apoyo docente, gestión académica y riesgo de sustitución como definiciones cerradas, este capítulo los usa como puntos de observación. Cada punto permite examinar que sabe la institución, que no sabe todavía y que decisión sería prudente antes de avanzar.

Cuando inteligencia artificial aplicada a la Educación Superior pasa al plano institucional, mirado desde la gestión, el problema no es tener más datos, sino usarlos mejor. Inteligencia artificial aplicada a la Educación Superior exige que la institución distinga entre señales accionables, ruido operativo y condiciones que requieren acompañamiento humano.

Inteligencia artificial aplicada a la Educación Superior exige una cautela sencilla: ningún dato debe cerrar por sí solo la interpretación. El apartado exige prudencia porque toda clasificación puede generar efectos. Nombrar una necesidad, priorizar un apoyo o anticipar un riesgo modifica la relación entre estudiante e institución.

Con ello, el análisis mantiene continuidad. El tema no se cierra en sí mismo; deja una pregunta que el apartado siguiente, dedicado a analítica educativa y minería de datos educativos, deberá desarrollar.

En la Figura 2 se propone una lectura visual del circuito que conecta observación, análisis y acción.



**Figura 2.** Flujo de decisión para inteligencia artificial aplicada a la Educación Superior.

En inteligencia artificial aplicada a la Educación Superior, el diseño visual debería permitir leer entradas, criterios y salidas. Automatización funciona como entrada inicial, los componentes intermedios como filtros y riesgo de sustitución como salida sujeta a seguimiento.

En inteligencia artificial aplicada a la Educación Superior, al llevarlo a la gestión académica, la conclusión parcial es que inteligencia artificial aplicada a la Educación Superior debe evaluarse por su aporte al aprendizaje y por la calidad institucional de las decisiones que activa. Esa idea conduce a analítica educativa y minería de datos educativos, donde el problema vuelve a formularse desde otra responsabilidad institucional.

## 2.2. Analítica educativa y minería de datos educativos

Analítica educativa y minería de datos educativos recoge una inquietud que ya estaba presente en inteligencia artificial aplicada a la Educación Superior. La obra mantiene así una progresión entre contexto, evidencia y acción.

La entrada a analítica educativa y minería de datos educativos debe hacerse desde la decisión que ayuda a clarificar. En este punto, la tecnología debe leerse como parte de una decisión mayor. Diferenciar enfoques, objetivos, datos, métodos y niveles de análisis debe vincularse con la capacidad institucional de actuar a tiempo. Observar el aprendizaje demasiado tarde convierte la analítica en registro; observarlo con criterio permite ofrecer apoyo antes de que la dificultad se consolide. Este punto se apoya en Blumenstein y Liang et al. [10], [11].

Al analizar analítica educativa y minería de datos educativos, el análisis se sostiene cuando la relación entre analítica descriptiva y evidencia institucional organiza el sentido del apartado. Entre ambos se ubican minería de datos educativos e intervención pedagógica, que permiten pasar de la información inicial a una lectura situada del proceso de aprendizaje (Ver Tabla 8).

**Tabla 8.** Criterios aplicados para analítica educativa y minería de datos educativos.

Tipo de análisis	Información que aporta	Uso pedagógico responsable
Analítica descriptiva	Muestra lo que está ocurriendo en el proceso formativo: participación, rendimiento, avance, acceso a recursos o cumplimiento de actividades.	Usarla como punto de partida para identificar señales, no como explicación definitiva del aprendizaje.
Minería de datos educativos	Permite reconocer patrones, relaciones o tendencias que no siempre son visibles mediante observación directa.	Contrastar los patrones con el contexto académico antes de convertirlos en intervención.
Intervención pedagógica	Traduce la información disponible en una acción educativa concreta: apoyo, ajuste, retroalimentación o seguimiento.	Aplicarla solo cuando exista evidencia suficiente y una lectura docente o institucional que la justifique.
Evidencia institucional	Integra datos acumulados sobre procesos, apoyos, resultados y decisiones académicas.	Usarla para evaluar qué acciones funcionan, corregir procedimientos y mejorar la gestión del acompañamiento.

La matriz permite reconocer dónde termina la observación y dónde empieza la responsabilidad institucional. Esta distinción es central porque la analítica educativa

y la minería de datos educativos no deben entenderse únicamente como herramientas para producir reportes, gráficos o alertas. Su valor aparece cuando la información generada permite comprender mejor el proceso de aprendizaje y orientar decisiones pedagógicas oportunas, justificadas y revisables.

Cuando analítica educativa y minería de datos educativos se aplica en una institución, una decisión bien administrada combina evidencia, criterio y seguimiento. En este tema, eso significa que minería de datos educativos debe dialogar con intervención pedagógica antes de activar una respuesta sobre evidencia institucional.

El punto delicado en analítica educativa y minería de datos educativos está en conservar margen para revisar la recomendación del sistema. Una dificultad frecuente consiste en actuar demasiado rápido. Antes de convertir minería de datos educativos en intervención, la institución debe revisar si la evidencia es suficiente y si la respuesta no agrava desigualdades previas. Este desarrollo también evita que la obra salte de un concepto a otro. La conexión con fuentes de datos para comprender el aprendizaje muestra que cada decisión educativa necesita una base anterior.

La analítica descriptiva cumple una primera función: mostrar qué está ocurriendo. Permite identificar niveles de participación, cumplimiento de actividades, rendimiento académico, frecuencia de acceso a plataformas o patrones generales de avance. Sin embargo, describir no equivale a explicar. Un dato puede señalar una dificultad, pero no determina por sí mismo su causa. Por ello, la información descriptiva debe ser leída como punto de partida y no como conclusión definitiva.

La minería de datos educativos amplía esa posibilidad porque permite identificar relaciones, patrones y tendencias que no siempre son visibles mediante una revisión manual. Puede ayudar a detectar trayectorias de riesgo, comportamientos recurrentes o asociaciones entre desempeño, participación y permanencia. No obstante, su uso exige cautela. La identificación de patrones no debe convertirse automáticamente en una intervención, porque el aprendizaje está atravesado por condiciones personales, pedagógicas, tecnológicas e institucionales que requieren interpretación contextual.

En este punto, la intervención pedagógica se vuelve el criterio que da sentido a la información. Una institución no analiza datos solo para conocerlos, sino para decidir si corresponde acompañar, ajustar, reforzar, flexibilizar, derivar o hacer seguimiento. La calidad de la intervención depende de que la evidencia sea suficiente, de que el docente o equipo académico pueda interpretarla y de que exista una respuesta proporcional al problema identificado. Actuar sin esa revisión puede llevar a decisiones apresuradas o poco pertinentes.

La evidencia institucional permite cerrar el circuito. Cuando los datos se organizan de manera sistemática, la institución puede aprender de sus propias decisiones: qué apoyos funcionaron, qué alertas fueron útiles, qué intervenciones llegaron tarde y qué factores se repiten en determinadas trayectorias estudiantiles.

Así, la analítica educativa deja de ser un mecanismo de control y se convierte en una herramienta para mejorar la gestión académica, la planificación curricular y el acompañamiento estudiantil.

En analítica educativa y minería de datos educativos, la conclusión parcial debe ser prudente: observar más no significa necesariamente comprender mejor. La comprensión aparece cuando los datos se interpretan con criterio pedagógico, se contrastan con el contexto y se traducen en acciones formativas responsables. Por eso, el capítulo avanza sin perder su eje: personalizar significa acompañar mejor, no automatizar más.

Lo desarrollado aquí se completa en fuentes de datos para comprender el aprendizaje, que desplaza la atención hacia el siguiente nivel del sistema. Después de revisar qué puede hacer la analítica, corresponde examinar de dónde proviene la información, qué tan confiable es, qué límites presenta y cómo puede utilizarse sin reducir la complejidad del aprendizaje a registros parciales.

### 2.3. Fuentes de datos para comprender el aprendizaje

El apartado se apoya en lo discutido sobre analítica educativa y minería de datos educativos, pero desplaza la atención hacia fuentes de datos para comprender el aprendizaje. Ese desplazamiento permite precisar mejor las condiciones de uso del modelo híbrido.

Para leer fuentes de datos para comprender el aprendizaje con provecho, conviene pasar pronto de la categoría general a la situación que debe resolverse. Una lectura responsable comienza por reconocer los límites del dato disponible. Describir datos de plataformas, evaluaciones, interacción, desempeño y contexto institucional invita a mirar el modelo como una herramienta de deliberación. La recomendación automatizada puede ser un insumo, pero la decisión final necesita contexto, conversación académica y seguimiento. Los aportes de Lon y Kaeser ayudan a delimitar ese uso [12]. En este punto, la Tabla 9 ayuda a diferenciar los componentes que deben revisarse antes de usar el modelo en una decisión real.

**Tabla 9.** Criterios aplicados para fuentes de datos para comprender el aprendizaje.

Fuente de datos	Qué permite observar	Límite de interpretación
Datos del LMS	Accesos, tiempos de conexión, entrega de actividades, uso de recursos, interacción con materiales y continuidad en la plataforma.	No explican por sí solos el aprendizaje; mucha actividad no siempre significa comprensión y poca actividad no siempre implica desinterés.
Evaluaciones	Resultados, avances, dificultades, niveles de logro y desempeño frente a objetivos formativos.	Una calificación no revela automáticamente la causa del resultado; debe contrastarse con contexto, participación y condiciones del estudiante.
Participación	Interacción con docentes, compañeros, actividades, foros, retroalimentaciones y espacios de aprendizaje.	Puede estar condicionada por acceso tecnológico, tiempo disponible, confianza, modalidad de estudio o barreras personales e institucionales.
Contexto académico	Trayectoria previa, carga académica, modalidad, condiciones de acceso, apoyos disponibles y características de la asignatura.	Requiere interpretación cuidadosa; no debe usarse para justificar etiquetas, sino para comprender mejor la situación del estudiante.

El cuadro deja lista la comparación entre criterios, actores y decisiones antes de pasar al cierre del apartado. Esta organización permite reconocer que las fuentes de datos para comprender el aprendizaje no tienen el mismo valor ni cumplen la misma función

dentro del modelo. Algunos datos permiten observar actividad, otros permiten valorar desempeño, otros ayudan a interpretar participación y otros aportan condiciones contextuales que modifican el sentido de cualquier indicador.

Al analizar fuentes de datos para comprender el aprendizaje, la decisión educativa se entiende mejor si el recorrido conceptual se sostiene en cuatro piezas: datos del les, evaluaciones, participación y contexto académico. La primera permite iniciar el diagnóstico; la segunda muestra movimiento; la tercera incorpora condiciones reales; y la cuarta exige transformar el análisis en apoyo.

Desde la coordinación académica, fuentes de datos para comprender el aprendizaje se vuelve manejable cuando el modelo híbrido funciona como apoyo cuando permite que distintas áreas miren el mismo caso con lenguaje común. Así, datos del les no se interpreta de forma aislada y contexto académico puede planificarse con mayor coherencia.

El riesgo, en fuentes de datos para comprender el aprendizaje, aparece cuando la institución actúa con más rapidez que criterio. El uso responsable implica conservar una puerta de salida. Si el análisis sobre datos del les no describe bien la situación, el estudiante y el docente deben tener formas claras de corregir la lectura.

Los datos del LMS ofrecen una primera aproximación al comportamiento académico del estudiante. Permiten revisar accesos, tiempos de conexión, entrega de actividades, uso de materiales, interacción con recursos y seguimiento de tareas. Sin embargo, estos datos no explican por sí solos el aprendizaje. Un estudiante puede ingresar poco a la plataforma y aun así comprender los contenidos; otro puede registrar mucha actividad sin alcanzar un aprendizaje significativo. Por ello, los datos del LMS deben leerse como señales iniciales, no como evidencias concluyentes.

Las evaluaciones aportan una dimensión distinta porque permiten observar resultados, avances, dificultades y niveles de logro. No obstante, tampoco deben analizarse de manera aislada. Una calificación baja puede reflejar falta de comprensión, pero también problemas de acceso, escasa claridad en la consigna, dificultades personales, poca retroalimentación o desajuste entre la actividad y el

objetivo formativo. Por esta razón, las evaluaciones deben dialogar con otras fuentes antes de activar una decisión pedagógica.

La participación amplía el análisis porque incorpora la forma en que el estudiante se vincula con el proceso educativo. Participar no significa únicamente responder en foros o asistir a clases. También implica preguntar, solicitar apoyo, colaborar, revisar retroalimentaciones, sostener continuidad y tomar parte activa en las actividades propuestas.

La participación debe interpretarse con cuidado, porque puede estar condicionada por factores tecnológicos, laborales, familiares, emocionales o institucionales.

El contexto académico permite integrar esas señales dentro de una lectura más completa. La trayectoria previa del estudiante, las condiciones de acceso, la carga académica, la modalidad de estudio, las características de la asignatura y los apoyos disponibles pueden modificar el significado de los datos. Sin esta información, el modelo corre el riesgo de producir una lectura incompleta y de recomendar acciones que no responden a la situación real.

En fuentes de datos para comprender el aprendizaje, el plano institucional exige una regla clara: ninguna fuente debe convertirse por sí sola en fundamento absoluto de una decisión. El valor del modelo híbrido aparece cuando permite cruzar datos, contrastar evidencias y abrir espacios de interpretación entre docentes, tutores, coordinación académica y áreas de apoyo. Así, la información deja de ser un registro disperso y se convierte en una base para decidir con mayor responsabilidad.

El resultado es una lectura aplicada del tema, orientada a decisiones que puedan sostenerse pedagógica y éticamente. Comprender el aprendizaje implica observar datos, pero también reconocer sus límites, revisar su calidad y definir qué tipo de acción puede justificarse a partir de ellos. Por esa razón, modelado del estudiante: perfiles, estados y trayectorias no aparece como tema separado, sino como continuación del mismo proceso de decisión: después de identificar las fuentes de información, corresponde analizar cómo esas evidencias permiten construir una representación más precisa, dinámica y revisable del estudiante.

## **2.4. Modelado del estudiante: perfiles, estados y trayectorias**

Después de revisar fuentes de datos para comprender el aprendizaje, el análisis avanza hacia modelado del estudiante: perfiles, estados y trayectorias. El apartado anterior deja una condición de trabajo y esta muestra como esa condición se convierte en una decisión más precisa.

Modelado del estudiante: perfiles, estados y trayectorias gana claridad cuando se lo vincula con una decisión docente, institucional o de acompañamiento. El tema gana sentido cuando se conecta con prácticas concretas de acompañamiento. Explicar cómo se representan conocimientos, preferencias, riesgos, progreso y necesidades no significa agregar una herramienta a un curso ni acumular indicadores en una plataforma. Lo importante es decidir qué información cambia la lectura del caso, quién debe revisarla y qué respuesta resulta proporcional. En ese marco, Peng y Li y Chat ti y Muslime ofrecen una base para tratar el tema con prudencia académica [13], [6].

Al analizar modelado del estudiante: perfiles, estados y trayectorias, en este punto, el tema se articula mediante perfil, estado de aprendizaje, trayectoria y necesidad de intervención. Perfil abre la lectura del problema; Estado de aprendizaje permite seguir su evolución; Trayectoria introduce el contexto donde la decisión toma forma; y Necesidad de intervención obliga a precisar que acción puede mejorar el aprendizaje.

En la gestión de modelado del estudiante: perfiles, estados y trayectorias, desde una mirada de administración académica, modelado del estudiante: perfiles, estados y trayectorias debe evaluarse por las decisiones que habilita. Un dato sobre perfil puede orientar una ruta, pero no debería cerrar la interpretación. También puede requerir contraste con docentes, historiales, condiciones de acceso y resultados previos.

La precaución básica en modelado del estudiante: perfiles, estados y trayectorias consiste en no confundir señal con explicación suficiente. El riesgo aparece cuando perfil se convierte en etiqueta y necesidad de intervención se transforma en

respuesta automática. Una salida más prudente combina reglas claras, revisión de umbrales y espacios donde el estudiante pueda ser escuchado.

En el uso institucional, este apartado retoma el problema anterior y lo vuelve más operativo. También anticipa sistemas de recomendación y entornos adaptativos, porque cada evidencia debe traducirse en criterios comprensibles para docentes y responsables académicos.

Ese recorrido se sintetiza en la Figura 3, pensada para mostrar el flujo entre datos, interpretación y decisión.



**Figura 3.** Flujo de decisión para modelado del estudiante: perfiles, estados y trayectorias.

En modelado del estudiante: perfiles, estados y trayectorias, el gráfico puede mostrar un recorrido que comienza en perfil, incorpora los demás componentes del tema como criterios de interpretación y termina en necesidad de intervención como decisión revisable. Conviene ubicar debajo una franja de mediación docente, seguimiento institucional y retroalimentación.

La figura se justifica porque modelado del estudiante: perfiles, estados y trayectorias describe un proceso, una arquitectura o una relación dinámica que se comprende mejor visualmente.

En modelado del estudiante: perfiles, estados y trayectorias, con este marco, en síntesis, modelado del estudiante: perfiles, estados y trayectorias aporta una condición de continuidad: permite pasar de la explicación conceptual a una decisión

educativa que pueda discutirse, aplicarse y revisarse. Desde aquí se abre el paso hacia sistemas de recomendación y entornos adaptativos, donde esa condición se examina con otro grado de detalle.

### **2.5. Sistemas de recomendación y entornos adaptativos**

El tema anterior, centrado en modelado del estudiante: perfiles, estados y trayectorias, abre una consecuencia práctica que ahora se desarrolla en sistemas de recomendación y entornos adaptativos. El paso natural consiste en pasar de una comprensión general a un criterio de actuación.

La discusión sobre sistemas de recomendación y entornos adaptativos gana cuerpo cuando se la vincula con responsabilidades, tiempos y efectos visibles. Para una institución, la diferencia entre información y decisión es decisiva. Analizar recomendaciones de recursos, actividades, rutas, apoyos y estrategias de aprendizaje exige separar la promesa tecnológica de la decisión educativa. Los datos pueden ampliar la mirada institucional, pero solo adquieren sentido cuando ayudan a comprender una necesidad, elegir una acción y revisar sus efectos. Esta lectura se sostiene en los aportes de Khosravi, Kitto y Williams y Chatti y Muslim [14], [6].

Al analizar sistemas de recomendación y entornos adaptativos, para avanzar, para que la exposición avance, conviene leer juntos recomendación de recursos, ruta adaptativa, criterio pedagógico y respuesta del estudiante. Recomendación de recursos no tiene valor aislado si no se relaciona con ruta adaptativa; Criterio pedagógico muestra las condiciones de uso; y Respuesta del estudiante convierte la información en una posibilidad de intervención. La Figura 4 permite visualizar mejor esta relación, porque el tema describe un movimiento entre componentes y no solo una comparación.



**Figura 4.** Flujo de decisión para sistemas de recomendación y entornos adaptativos.

En sistemas de recomendación y entornos adaptativos, la imagen puede organizarse como un mapa de relaciones. En el centro se ubica sistemas de recomendación y entornos adaptativos; a la izquierda aparecen las evidencias asociadas con recomendación de recursos, y a la derecha las acciones vinculadas con respuesta del estudiante. Las conexiones deben mostrar que ninguna decisión es puramente automática.

El recurso visual permite seguir el recorrido de la decisión sin convertirlo en una lista de criterios. Desde la coordinación académica, sistemas de recomendación y entornos adaptativos obliga a revisar que, para los equipos de gestión, sistemas de recomendación y entornos adaptativos plantea una exigencia concreta: transformar información dispersa en criterios compartidos. Si cada área interpreta recomendación de recursos de manera distinta, la respuesta vinculada con respuesta del estudiante se vuelve irregular y difícil de evaluar.

La institución debe tratar sistemas de recomendación y entornos adaptativos como una ayuda para interpretar, no como una sentencia sobre el estudiante. El límite más delicado surge cuando la institución confunde predicción con destino. Una señal sobre recomendación de recursos puede advertir una dificultad, pero no autoriza a reducir la trayectoria del estudiante a una clasificación.

El razonamiento pasa ahora de la comprensión a la acción. Lo discutido aquí prepara modelos predictivos para apoyo académico, donde la decisión necesita nuevos criterios y otra escala de análisis.

En sistemas de recomendación y entornos adaptativos, desde esta perspectiva, el aprendizaje principal del apartado es que sistemas de recomendación y entornos adaptativos solo tiene valor cuando mejora una decisión concreta y deja trazabilidad sobre sus efectos. El apartado siguiente, dedicado a modelos predictivos para apoyo académico, retoma esta misma preocupación desde una dimensión complementaria.

### **2.6. Modelos predictivos para apoyo académico**

Sistemas de recomendación y entornos adaptativos preparo el terreno para esta discusión. Ahora, modelos predictivos para apoyo académico permite observar el mismo problema desde otro nivel de decisión.

Para leer modelos predictivos para apoyo académico con provecho, conviene pasar pronto de la categoría general a la situación que debe resolverse. El enfoque resulta más sólido cuando combina claridad conceptual y prudencia operativa. Revisar predicción de rendimiento, riesgo, participación y necesidades de intervención debe leerse como un problema de gestión pedagógica. Una señal sin mediación puede ordenar el tablero, pero no necesariamente mejora la enseñanza. Los trabajos de Waddington et al. permiten ubicar esa relacion entre evidencia y acción [15].

El riesgo, en modelos predictivos para apoyo académico, aparece cuando la institución actúa con más rapidez que criterio. También existe un riesgo de exceso de confianza. Si el sistema presenta intervención temprana como solución evidente, puede ocultar condiciones que no están en los datos y que solo aparecen mediante dialogo pedagógico.

Este punto conecta hacia adelante porque ninguna arquitectura inteligente opera en el vacío. Lo que se define aquí como criterio volverá a aparecer en tableros de analítica y toma de decisiones académicas como condición de aplicación.

Como se muestra en la Figura 5, el modelo requiere pasar por varias mediaciones antes de producir una recomendación útil.



**Figura 5.** Flujo de decisión para modelos predictivos para apoyo académico.

En modelos predictivos para apoyo académico, se recomienda representar tres capas: datos disponibles, interpretación pedagógica y respuesta institucional. Rendimiento inicia la lectura, mientras intervención temprana marca el punto donde la decisión debe documentarse y revisarse.

En este caso, la figura ayuda a ubicar entradas, mediaciones y salidas del sistema de forma más clara que una tabla. Al analizar modelos predictivos para apoyo académico, la lectura gana claridad cuando la secuencia conceptual parte de rendimiento, pasa por riesgo académico y participación, y desemboca en intervención temprana. Esa progresión evita que el apartado sea una enumeración y permite leer cada componente como parte de una decisión educativa mayor.

Desde la coordinación académica, modelos predictivos para apoyo académico se vuelve manejable cuando el enfoque gerencial ayuda a ordenar responsabilidades. La cadena de trabajo empieza con la observación, pasa por riesgo académico y termina evaluando si intervención temprana produjo un cambio verificable.

En modelos predictivos para apoyo académico, visto así, la idea que queda es prudente: el modelo híbrido ayuda si amplía la comprensión del aprendizaje, no si reemplaza el juicio académico por una clasificación rápida. Con esta base, tableros de analítica y toma de decisiones académicas puede analizarse sin perder la relación entre datos, criterio y acción.

## **2.7. Tableros de analítica y toma de decisiones académicas**

El recorrido no cambia de dirección; se vuelve más específico. Lo trabajado en modelos predictivos para apoyo académico encuentra aquí, en tableros de analítica y toma de decisiones académicas, una aplicación más concreta.

Antes de convertir tableros de analítica y toma de decisiones académicas en procedimiento, hace falta precisar qué problema educativo permite mirar con más cuidado. La discusión requiere una mirada doble: pedagógica e institucional. Estudiar visualización, interpretación y uso responsable de indicadores para docentes y gestores plantea una pregunta de fondo: que puede hacer mejor la institución cuando comprende el aprendizaje con mayor detalle. La respuesta no está en automatizar la decisión, sino en precisar que información ayuda, que límite tiene y como se traduce en apoyo. Ramaswami, Susnjak y Mathrani y Blumenstein sirven aquí como referencias principales [16],[10].

Tableros de analítica y toma de decisiones académicas exige una cautela sencilla: ningún dato debe cerrar por sí solo la interpretación. Una lectura responsable debe reconocer que interpretación docente puede alterar el significado de cualquier indicador. Dos estudiantes con la misma señal pueden necesitar respuestas distintas. El argumento avanza así de manera gradual: primero se delimita el problema, luego se precisan los componentes y después se abre el camino hacia concepto de modelo híbrido inteligente.

La Figura 6 traduce el argumento en un esquema de proceso, con entradas, criterios y salidas revisables.



**Figura 6.** Flujo de decisión para tableros de analítica y toma de decisiones académicas.

En tableros de analítica y toma de decisiones académicas, la figura puede dibujarse como un ciclo. Primero se observa indicador; luego se contrastan los componentes intermedios; finalmente se decide sobre decisión académica y se vuelve al sistema con nueva información de seguimiento.

Al analizar tableros de analítica y toma de decisiones académicas, el desarrollo del tema exige observar que los cuatro componentes del apartado cumplen funciones distintas. Indicador orienta el diagnóstico inicial; Visualización ayuda a reconocer cambios; Interpretación docente protege la lectura contextual; y Decisión académica permite cerrar el circuito con una respuesta formativa.

Cuando tableros de analítica y toma de decisiones académicas pasa al plano institucional, en una institución, tableros de analítica y toma de decisiones académicas no puede depender de intuiciones individuales ni de cálculos opacos. Necesita procedimientos claros, registros simples y espacios donde la evidencia se discuta antes de convertirse en decisión.

La representación gráfica permite ver la secuencia de actores, datos y decisiones que sostienen el tema. En tableros de analítica y toma de decisiones académicas, el punto que conviene retener es este: al cerrar el tema, conviene retener una regla sencilla: toda personalización debe poder explicarse al estudiante, al docente y a la institución. El siguiente tema, concepto de modelo híbrido inteligente, permite continuar la secuencia y revisar nuevas implicaciones del modelo.

A partir de estos fundamentos tecnológicos, la siguiente sección integra las piezas en una arquitectura híbrida.

## Fundamentos y arquitectura de los modelos híbridos inteligentes

La tercera sección desarrolla el núcleo de la obra: el modelo híbrido inteligente. La palabra híbrido no indica una mezcla decorativa, sino una arquitectura que combina datos, reglas, conocimiento experto, modelos predictivos y criterios pedagógicos. Esa combinación importa porque el aprendizaje universitario rara vez se explica desde una sola variable.

### 3.1. Concepto de modelo híbrido inteligente

Para mantener el hilo del libro, concepto de modelo híbrido inteligente debe leerse como continuación de tableros de analítica y toma de decisiones académicas. La diferencia está en el tipo de evidencia y en la responsabilidad que cada decisión activa.

Antes de convertir concepto de modelo híbrido inteligente en procedimiento, hace falta precisar qué problema educativo permite mirar con más cuidado. Aquí conviene evitar respuestas rápidas y revisar primero el proceso completo. Definir el modelo híbrido como integración de técnicas, datos, reglas y criterios pedagógicos requiere una lectura menos instrumental de la tecnología. Un sistema puede ordenar datos y sugerir rutas, aunque la pertinencia de esas rutas depende de su relación con objetivos, contexto y mediación docente. Esa cautela requiere una cita solo cuando el documento fuente trate de manera explícita la relación entre contexto, mediación y ruta.

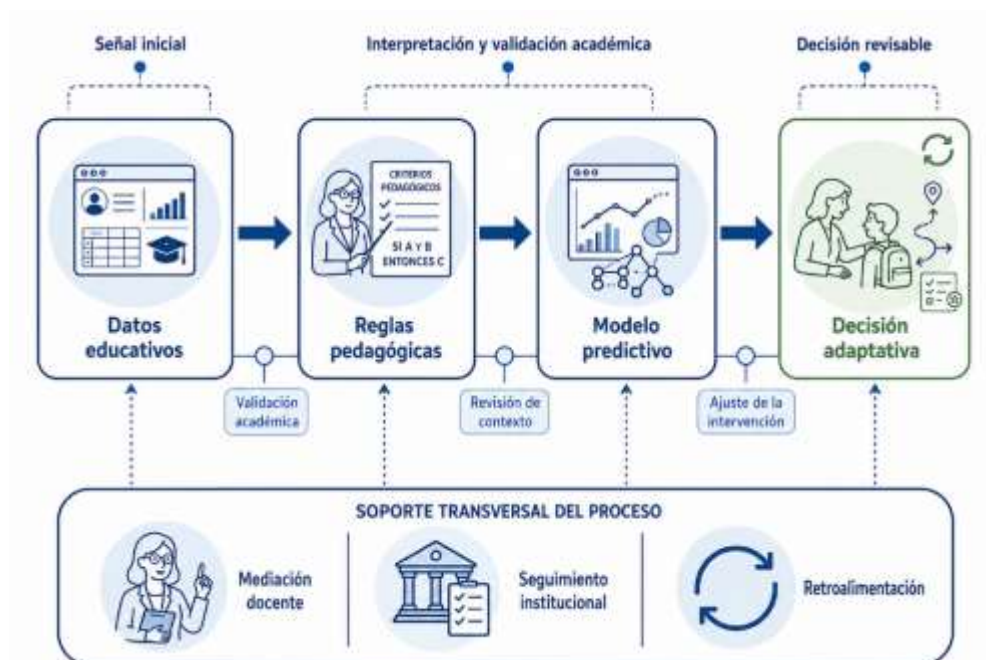
Al analizar concepto de modelo híbrido inteligente, la exposición se ordena mejor si leídos en conjunto, datos educativos, reglas pedagógicas, modelo predictivo y decisión adaptativa forman una cadena de decisión. Primero aparece una señal, luego se interpreta su trayectoria, después se revisa el contexto y finalmente se define una acción que pueda ser observada y corregida.

Cuando concepto de modelo híbrido inteligente pasa al plano institucional, la utilidad del modelo se mide en la coordinación que produce. Cuando docencia, bienestar, tecnología y dirección curricular trabajan con el mismo criterio, datos educativos deja de ser un dato suelto y se vuelve parte de una estrategia. Concepto de modelo híbrido

inteligente exige una cautela sencilla: ningún dato debe cerrar por sí solo la interpretación. El problema no está en usar datos, sino en usarlos sin contexto. Cuando reglas pedagógicas se interpreta sin mediación, el modelo puede producir decisiones ordenadas, aunque pedagógicamente pobres.

La relación con el tema siguiente es práctica. Si concepto de modelo híbrido inteligente no se resuelve con claridad, integración de enfoques simbólicos y aprendizaje automático quedara apoyado sobre supuestos frágiles.

Para que el lector ubique la secuencia completa, la Figura 7 resume el flujo de decisión asociado con el tema.



**Figura 7.** Flujo de decisión para concepto de modelo híbrido inteligente.

En concepto de modelo híbrido inteligente, el esquema visual debe destacar que concepto de modelo híbrido inteligente no es una secuencia cerrada. Entre datos educativos y decisión adaptativa deben aparecer puntos de validación académica, revisión de contexto y ajuste de la intervención.

El valor de la figura está en mostrar conexiones; por eso resulta más adecuada que una matriz comparativa.

En concepto de modelo híbrido inteligente, la consecuencia para el libro es clara: visto en conjunto, concepto de modelo híbrido inteligente fortalece la obra porque

---

conecta datos, mediación y seguimiento dentro de una misma lógica de responsabilidad. A partir de este punto, integración de enfoques simbólicos y aprendizaje automático aparece como una consecuencia natural del argumento.

### **3.2. Integración de enfoques simbólicos y aprendizaje automático**

El paso desde concepto de modelo híbrido inteligente hacia integración de enfoques simbólicos y aprendizaje automático permite afinar el argumento. Ya no se trata solo de reconocer el problema, sino de establecer como puede gestionarse.

Para comprender integración de enfoques simbólicos y aprendizaje automático, conviene mirar primero qué decisión académica vuelve más precisa. La utilidad del modelo depende de la calidad de la pregunta que intenta resolver. Explicar la combinación entre reglas explícitas, ontologías, modelos estadísticos y aprendizaje automático se vuelve útil cuando conecta información disponible con decisiones que alguien puede explicar. Si la institución no sabe por qué actúa, el modelo pierde valor pedagógico, aunque funcione técnicamente. Ese equilibrio debe quedar respaldado por evidencia textual antes de transformarse en una afirmación citada.

Al analizar integración de enfoques simbólicos y aprendizaje automático, el argumento se vuelve más concreto cuando no todos los elementos pesan igual en cada institución. A veces regla explícita ofrece la señal principal; en otros casos, modelo estadístico explica mejor la dificultad. Lo importante es que aprendizaje automático no sea una reacción automática, sino una respuesta fundada. En el uso cotidiano de integración de enfoques simbólicos y aprendizaje automático, administrar este proceso implica aceptar que la información educativa siempre es incompleta. Por eso, la recomendación del sistema debe abrir una conversación sobre modelo estadístico, no reemplazarla.

El proceso descrito puede representarse en la Figura 8, donde la mediación académica aparece como parte del sistema y no como un agregado externo.



**Figura 8.** Flujo de decisión para integración de enfoques simbólicos y aprendizaje automático.

El punto delicado en integración de enfoques simbólicos y aprendizaje automático está en conservar margen para revisar la recomendación del sistema. La automatización resulta útil mientras conserve puntos de revisión. Si una recomendación sobre aprendizaje automático no puede explicarse, discutirse o corregirse, el sistema pierde legitimidad educativa. Este apartado funciona como bisagra dentro del capítulo. Recoge lo anterior, ordena sus implicaciones y deja planteada la necesidad de revisar arquitectura general de un modelo híbrido para personalización.

En integración de enfoques simbólicos y aprendizaje automático, una opción clara es usar un diagrama de flujo con cuatro nodos principales. El primer nodo corresponde a regla explícita; el último a aprendizaje automático; entre ambos se ubican los criterios que permiten pasar de observación a decisión. Con este esquema, el lector puede observar el movimiento del modelo y no solo sus componentes separados.

En integración de enfoques simbólicos y aprendizaje automático, en términos pedagógicos, el cierre operativo es claro: una decisión personalizada necesita evidencia suficiente, criterio pedagógico y posibilidad de corrección. La discusión queda preparada para avanzar hacia arquitectura general de un modelo híbrido para personalización, sin romper el hilo pedagógico de la obra.

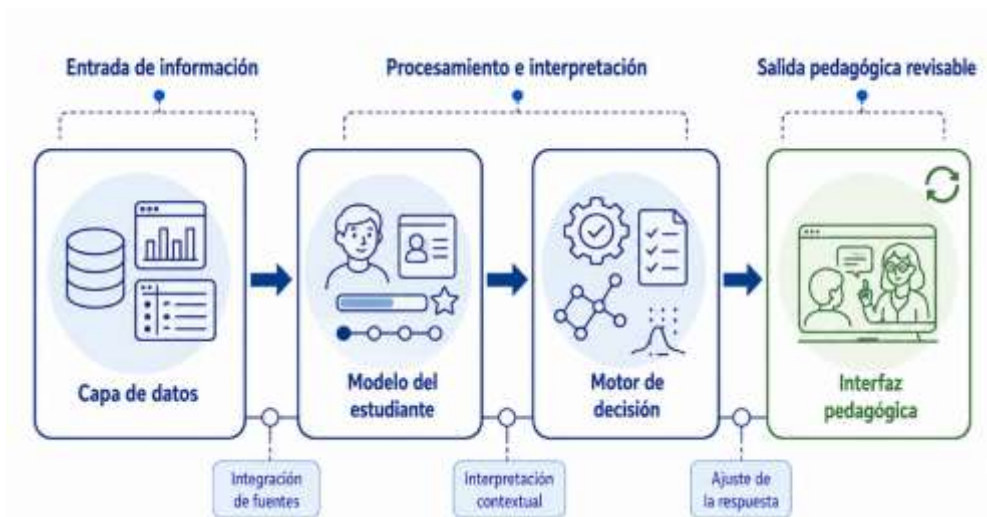
### **3.3. Arquitectura general de un modelo híbrido para personalización**

La sección avanza de manera acumulativa. Integración de enfoques simbólicos y aprendizaje automático dejó planteado un límite; arquitectura general de un modelo híbrido para personalización examina una forma de responderlo.

Arquitectura general de un modelo híbrido para personalización gana claridad cuando se lo vincula con una decisión docente, institucional o de acompañamiento. Cuando se lleva al aula universitaria, cada recomendación necesita una razón comprensible. Proponer componentes para datos, modelo del estudiante, motor de decisión, capa pedagógica e interfaz no puede reducirse a una operación técnica. Implica reconocer condiciones de aprendizaje, valorar evidencias parciales y decidir apoyos que no cierren la trayectoria del estudiante de antemano. Las referencias de Chat ti y Muslime y Lon y Kaeser permiten sostener esa interpretación [6], [12].

Al analizar arquitectura general de un modelo híbrido para personalización, la relación interna del tema muestra que el apartado gana fuerza cuando capa de datos, modelo del estudiante, motor de decisión e interfaz pedagógica se leen como partes de un mismo proceso. Cada elemento aporta una pregunta distinta, y la suma de esas preguntas ayuda a construir una intervención más responsable. En la gestión de arquitectura general de un modelo híbrido para personalización, el valor institucional aparece cuando la lectura de capa de datos ayuda a actuar con oportunidad. Esa oportunidad, sin embargo, necesita controles: trazabilidad, responsables definidos y revisión periódica de efectos.

La Figura 9 muestra ese recorrido sin sugerir que la respuesta educativa salga de forma automática.



**Figura 9.** Flujo de decisión para arquitectura general de un modelo híbrido para personalización.

La precaución básica en arquitectura general de un modelo híbrido para personalización consiste en no confundir señal con explicación suficiente. Conviene evitar una lectura determinista. capa de datos puede orientar una decisión, pero la acción institucional debe considerar historia académica, condiciones materiales y percepción del estudiante. La secuencia del libro requiere esta pausa: antes de avanzar hacia ontologías, reglas pedagógicas y conocimiento experto, es necesario reconocer que toda decisión personalizada depende de criterios previos.

En arquitectura general de un modelo híbrido para personalización, la representación puede mostrar una ruta de decisión acompañada por dos controles transversales: responsabilidad pedagógica y protección de datos. Estos controles atraviesan el proceso desde capa de datos hasta interfaz pedagógica. La figura concentra el sentido operativo del apartado: como una señal se transforma en interpretación y luego en acción.

En arquitectura general de un modelo híbrido para personalización, el aporte del apartado puede resumirse así: este apartado deja una advertencia útil: la sofisticación técnica no compensa una lectura pobre del contexto educativo. El lector puede pasar ahora a ontologías, reglas pedagógicas y conocimiento experto con una pregunta más precisa sobre el uso responsable de la personalización.

### **3.4. Ontologías, reglas pedagógicas y conocimiento experto**

Antes de entrar en ontologías, reglas pedagógicas y conocimiento experto, conviene recordar el punto previo: arquitectura general de un modelo híbrido para personalización. Esa referencia evita que el nuevo tema aparezca como bloque aislado.

Ontologías, reglas pedagógicas y conocimiento experto no se agota en una definición; necesita mostrar su utilidad frente a una decisión académica. La idea puede parecer sencilla, pero en el uso institucional exige una distinción importante. Examinar representación de contenidos, competencias, prerrequisitos y criterios docentes introduce un criterio práctico para la Educación Superior: usar tecnología solo cuando mejora la comprensión del proceso formativo. Los indicadores, por sí solos, no enseñan; orientan cuando se insertan en una decisión pedagógica clara. Esa perspectiva dialoga con Bayly-Castaneda, Ramírez-Montoya y Morita-Alexander [17].

Al analizar ontologías, reglas pedagógicas y conocimiento experto, para evitar una lectura fragmentada, en lugar de tratar competencia, prerrequisito, regla docente y relación conceptual como definiciones cerradas, este capítulo los usa como puntos de observación. Cada punto permite examinar que sabe la institución, que no sabe todavía y que decisión sería prudente antes de avanzar.

Con ello, el análisis mantiene continuidad. El tema no se cierra en sí mismo; deja una pregunta que el apartado siguiente, dedicado a algoritmos, modelos de clasificación y predicción educativa, deberá desarrollar. El modo en que estos elementos se traducen en decisiones se aprecia en la Tabla 10.

**Tabla 10.** Criterios aplicados para ontologías, reglas pedagógicas y conocimiento experto.

Elemento de conocimiento	Función dentro del modelo	Decisión que fortalece
Competencia	Define qué aprendizaje debe desarrollar el estudiante y permite relacionar contenidos, actividades y evaluaciones.	Determinar si la recomendación responde a un objetivo formativo concreto.
Prerrequisito	Identifica conocimientos, habilidades o condiciones previas necesarias para avanzar en una secuencia de aprendizaje.	Decidir si el estudiante puede continuar, necesita refuerzo o requiere una actividad previa.
Regla docente	Incorpora criterios pedagógicos definidos por docentes o académicos para orientar recomendaciones.	Ajustar la intervención según experiencia docente, dificultad del contenido y necesidad de equipos formativos.
Relación conceptual	Organiza vínculos entre temas, recursos, actividades y niveles de complejidad.	Evitar recomendaciones aisladas y construir rutas de aprendizaje coherentes.

El cuadro invita a una lectura deliberativa; ayuda a conversar sobre el modelo sin sustituir la discusión académica que toda personalización requiere. Esta distinción es importante porque las ontologías, las reglas pedagógicas y el conocimiento experto no deben entenderse como componentes técnicos aislados, sino como recursos que permiten organizar el conocimiento institucional sobre el aprendizaje, los contenidos y las decisiones formativas.

En el plano operativo, ontologías muestra que reglas pedagógicas y conocimiento experto, mirado desde la gestión, el problema no es tener más datos, sino usarlos mejor. Ontologías, reglas pedagógicas y conocimiento experto exige que la institución distinga entre señales accionables, ruido operativo y condiciones que requieren acompañamiento humano.

En ontologías, reglas pedagógicas y conocimiento experto, la cautela consiste en leer la señal junto con las condiciones que la producen. El apartado exige prudencia porque toda clasificación puede generar efectos. Nombrar una necesidad, priorizar un apoyo o anticipar un riesgo modifica la relación entre estudiante e institución.

Permiten representar relaciones entre conceptos, competencias, resultados de aprendizaje, actividades, recursos y prerrequisitos. Su valor no está únicamente en ordenar información, sino en hacer visible cómo se conectan los elementos del proceso educativo. Cuando una institución sabe qué competencia depende de qué contenido, qué actividad fortalece determinado resultado o qué prerrequisito condiciona el avance del estudiante, puede tomar decisiones más claras y justificadas.

Las reglas pedagógicas cumplen una función complementaria. Permiten traducir criterios docentes en orientaciones para el modelo. Por ejemplo, una regla puede indicar que antes de recomendar una actividad avanzada conviene verificar ciertos aprendizajes previos, o que una dificultad persistente requiere retroalimentación específica antes de pasar a una nueva unidad. De esta manera, el modelo no actúa solo con patrones estadísticos, sino también con criterios pedagógicos explícitos.

El conocimiento experto aporta el juicio acumulado de docentes, tutores, coordinadores y equipos académicos. Este conocimiento permite reconocer situaciones que los datos no siempre capturan: dificultades recurrentes en una asignatura, errores frecuentes en una competencia, secuencias conceptuales complejas o condiciones que afectan el desempeño estudiantil. Incorporar este conocimiento evita que el modelo dependa únicamente de registros de plataforma o resultados cuantitativos.

En este sentido, la relación conceptual es clave porque permite comprender que el aprendizaje no ocurre como una suma de datos separados.

Una competencia se construye mediante contenidos, prácticas, retroalimentaciones, evaluaciones y condiciones previas. Si el modelo no representa esas relaciones, puede recomendar acciones fragmentadas o poco pertinentes. Por el contrario, cuando esas conexiones están organizadas, la personalización puede responder mejor a la trayectoria real del estudiante.

Al llevarlo a la gestión académica, la conclusión parcial es que las ontologías, las reglas pedagógicas y el conocimiento experto deben evaluarse por su aporte al aprendizaje y por la calidad institucional de las decisiones que activan. Su utilidad no se mide solo por la sofisticación del sistema, sino por su capacidad para hacer más comprensible

el proceso formativo, orientar apoyos razonables y permitir que las recomendaciones sean discutidas, explicadas y corregidas.

Por ello, este apartado deja una idea central: representar el conocimiento educativo no significa cerrar la interpretación, sino mejorar las condiciones para decidir. Una ontología bien diseñada, una regla pedagógica clara y un criterio experto bien incorporado pueden fortalecer el modelo híbrido siempre que mantengan abierta la revisión docente y la responsabilidad institucional. Esa idea conduce a algoritmos, modelos de clasificación y predicción educativa, donde el problema vuelve a formularse desde otra responsabilidad: cómo usar procedimientos computacionales para anticipar necesidades sin reducir la complejidad del aprendizaje a una etiqueta o predicción automática.

### **3.5. Algoritmos, modelos de clasificación y predicción educativa**

Algoritmos, modelos de clasificación y predicción educativa recoge una inquietud que ya estaba presente en ontologías, reglas pedagógicas y conocimiento experto. La obra mantiene así una progresión entre contexto, evidencia y acción. Algoritmos, modelos de clasificación y predicción educativa se entiende mejor cuando se lo vincula con una decisión que puede explicarse y revisarse. En términos operativos, el punto decisivo está en cómo se convierte la información en acción. Presentar técnicas de clasificación, agrupamiento, recomendación y predicción con finalidad educativa debe vincularse con la capacidad institucional de actuar a tiempo. Observar el aprendizaje demasiado tarde convierte la analítica en registro; observarlo con criterio permite ofrecer apoyo antes de que la dificultad se consolide. Este punto se apoya en Penga y Li [13].

La operación de algoritmos exige que modelos de clasificación y predicción educativa, una decisión bien administrada combina evidencia, criterio y seguimiento. En este tema, eso significa que agrupamiento debe dialogar con predicción antes de activar una respuesta sobre validación. El punto delicado en algoritmos, modelos de clasificación y predicción educativa está en conservar margen para revisar la recomendación del sistema. Una dificultad frecuente consiste en actuar demasiado rápido. Antes de convertir agrupamiento en intervención, la institución debe revisar

si la evidencia es suficiente y si la respuesta no agrava desigualdades previas. Este desarrollo también evita que la obra salte de un concepto a otro. La conexión con interoperabilidad, plataformas y ecosistemas de datos muestra que cada decisión educativa necesita una base anterior (Ver Tabla 11).

**Tabla 11.** Criterios aplicados para modelos de clasificación y predicción educativa.

Elemento de conocimiento	Función dentro del modelo	Decisión que fortalece
Competencia	Define qué aprendizaje debe desarrollar estudiante y permite relacionar contenidos, actividades y evaluaciones.	Determinar si la recomendación responde a un objetivo formativo concreto.
Prerrequisito	Identifica conocimientos, habilidades o condiciones necesarias para avanzar en una secuencia de aprendizaje.	Decidir si el estudiante puede continuar, necesita refuerzo o requiere una actividad previa.
Regla docente	Incorpora criterios pedagógicos definidos por docentes o académicos para orientar recomendaciones.	Ajustar la intervención según experiencia docente, dificultad del contenido y necesidad de equipos formativa.
Relación conceptual	Organiza vínculos entre temas, recursos, actividades y niveles de complejidad.	Evitar recomendaciones aisladas y construir rutas de aprendizaje coherentes.

La matriz permite reconocer dónde termina la observación y dónde empieza la responsabilidad institucional. Esta diferencia es importante porque los algoritmos, los modelos de clasificación y la predicción educativa no deben entenderse como mecanismos automáticos de decisión, sino como recursos que ayudan a organizar información, identificar señales relevantes y orientar preguntas pedagógicas más precisas.

La clasificación permite ordenar casos, perfiles o situaciones de aprendizaje según ciertos criterios previamente definidos. Puede ayudar a reconocer estudiantes con riesgo académico, niveles de avance, patrones de desempeño o necesidades de apoyo. Sin embargo, clasificar no significa comprender por completo. Una categoría puede orientar la mirada institucional, pero no debe convertirse en una etiqueta fija ni en una explicación definitiva de la trayectoria del estudiante.

El agrupamiento amplía esta lectura porque permite identificar relaciones entre estudiantes, comportamientos o procesos que comparten características similares. Su utilidad aparece cuando ayuda a descubrir patrones que no eran evidentes para la institución. No obstante, esos grupos deben interpretarse con cuidado. Dos estudiantes pueden pertenecer al mismo grupo estadístico y, aun así, requerir apoyos distintos. Por ello, el agrupamiento debe funcionar como una señal inicial que exige contraste pedagógico antes de cualquier intervención.

La predicción educativa introduce una responsabilidad mayor. Anticipar riesgo, desempeño, permanencia o probabilidad de éxito puede ser útil si permite actuar a tiempo, pero también puede producir decisiones apresuradas si se interpreta como resultado inevitable. Una predicción no debe cerrar las posibilidades del estudiante ni anticipar su trayectoria como si estuviera determinada. Su valor está en abrir oportunidades de acompañamiento, no en justificar exclusiones, restricciones o intervenciones rígidas.

Por esta razón, la validación se convierte en un componente indispensable. Todo modelo debe ser revisado no solo por su precisión técnica, sino también por la pertinencia educativa de sus resultados. Validar implica preguntar si la clasificación es comprensible, si el agrupamiento tiene sentido pedagógico, si la predicción ayuda a intervenir mejor y si las decisiones derivadas pueden corregirse cuando el contexto cambia. Un modelo puede mostrar buenos resultados estadísticos y, al mismo tiempo, producir recomendaciones débiles si no considera las condiciones reales del proceso formativo.

En algoritmos, modelos de clasificación y predicción educativa, la conclusión parcial debe mantenerse prudente: personalizar no significa automatizar más, sino acompañar mejor con información más organizada, interpretable y revisable.

Los algoritmos aportan valor cuando permiten actuar con oportunidad, pero ese valor depende de la mediación docente, de la calidad de los datos, de la transparencia del procedimiento y de la capacidad institucional para corregir sus propias decisiones.

Lo desarrollado aquí se completa en interoperabilidad, plataformas y ecosistemas de datos, que desplaza la atención hacia el siguiente nivel del sistema. Después de

revisar cómo los algoritmos organizan, agrupan y anticipan información, corresponde analizar si las plataformas, los sistemas institucionales y los flujos de datos pueden sostener esas decisiones de manera coherente, segura y pedagógicamente responsable.

### **3.6. Interoperabilidad, plataformas y ecosistemas de datos**

El apartado se apoya en lo discutido sobre algoritmos, modelos de clasificación y predicción educativa, pero desplaza la atención hacia interoperabilidad, plataformas y ecosistemas de datos. Ese desplazamiento permite precisar mejor las condiciones de uso del modelo híbrido.

Para leer interoperabilidad, plataformas y ecosistemas de datos con provecho, conviene pasar pronto de la categoría general a la situación que debe resolverse. También conviene mirar el tema desde la organización que debe sostenerlo. Analizar integración con LMS, estándares, repositorios, sistemas académicos y flujos de datos invita a mirar el modelo como una herramienta de deliberación. La recomendación automatizada puede ser un insumo, pero la decisión final necesita contexto, conversación académica y seguimiento. Los aportes de Lon y Kaeser y Villegas-Ch y García-Ortiz ayudan a delimitar ese uso [12], [7].

Al analizar interoperabilidad, plataformas y ecosistemas de datos, la decisión educativa se entiende mejor si el recorrido conceptual se sostiene en cuatro piezas: les, repositorio, sistema académico y flujo de datos. La primera permite iniciar el diagnóstico; la segunda muestra movimiento; la tercera incorpora condiciones reales; y la cuarta exige transformar el análisis en apoyo.

El hilo conductor permanece: comprender mejor al estudiante para decidir mejor. Desde aquí, ciclo de vida de diseño, entrenamiento, validación y mejora aparece como el siguiente nivel de esa misma discusión.

La Figura 10 permite ver las capas que median entre el dato inicial y la acción sugerida.



**Figura 10.** Flujo de decisión para interoperabilidad, plataformas y ecosistemas de datos.

En interoperabilidad, plataformas y ecosistemas de datos, el recurso visual debe hacer visible la mediación humana. Aunque el flujo parta de los y llegue a flujo de datos, conviene incluir puntos donde docentes, estudiantes o equipos académicos puedan validar la interpretación. Desde la coordinación académica, interoperabilidad se vuelve manejable cuando plataformas y ecosistemas de datos, el modelo híbrido funciona como apoyo cuando permite que distintas áreas miren el mismo caso con lenguaje común. Así, les no se interpreta de forma aislada y flujo de datos puede planificarse con mayor coherencia.

El riesgo, en interoperabilidad, plataformas y ecosistemas de datos, aparece cuando la institución actúa con más rapidez que criterio. El uso responsable implica conservar una puerta de salida. Si el análisis sobre los no describe bien la situación, el estudiante y el docente deben tener formas claras de corregir la lectura.

En interoperabilidad, plataformas y ecosistemas de datos, en el plano institucional, el resultado es una lectura aplicada del tema, orientada a decisiones que puedan sostenerse pedagógica y éticamente. Por esa razón, ciclo de vida de diseño, entrenamiento, validación y mejora no aparece como tema separado, sino como continuación del mismo proceso de decisión.

### **3.7. Ciclo de vida de diseño, entrenamiento, validación y mejora**

Después de revisar interoperabilidad, plataformas y ecosistemas de datos, el análisis avanza hacia ciclo de vida de diseño, entrenamiento, validación y mejora. El apartado anterior deja una condición de trabajo y esta muestra como esa condición se convierte en una decisión más precisa.

Antes de convertir ciclo de vida de diseño, entrenamiento, validación y mejora en procedimiento, hace falta precisar qué problema educativo permite mirar con más cuidado. Sin embargo, el valor del enfoque no aparece en la técnica aislada. Describir fases para construir, evaluar, ajustar y supervisar modelos híbridos inteligentes no significa agregar una herramienta a un curso ni acumular indicadores en una plataforma. La pregunta práctica es más estrecha: qué dato merece atención, quién lo interpreta y qué apoyo puede activarse sin sobreactuar. En ese marco, Villegas-Ch y García-Ortiz y Hidalgo y Evans ofrecen una base para tratar el tema con prudencia académica [7], [18].

Al analizar ciclo de vida de diseño, entrenamiento, validación y mejora, en este punto, el tema se articula mediante diseño, entrenamiento, validación y mejora continua. Diseño abre la lectura del problema; Entrenamiento permite seguir su evolución; Validación introduce el contexto donde la decisión toma forma; y Mejora continua obliga a precisar que acción puede mejorar el aprendizaje.

Cuando ciclo de vida de diseño pasa al plano institucional, entrenamiento, validación y mejora, desde una mirada de administración académica, ciclo de vida de diseño, entrenamiento, validación y mejora debe evaluarse por las decisiones que habilita. Un dato sobre diseño puede orientar una ruta, pero no debería cerrar la interpretación. También puede requerir contraste con docentes, historiales, condiciones de acceso y resultados previos.

Ciclo de vida de diseño, entrenamiento, validación y mejora exige una cautela sencilla: ningún dato debe cerrar por sí solo la interpretación. El riesgo aparece cuando diseño se convierte en etiqueta y mejora continua se transforma en respuesta automática. El modelo debe dejar margen para revisar el caso cuando la señal no describa bien la situación del estudiante.

En condiciones reales de gestión, este apartado retoma el problema anterior y lo vuelve más operativo. También anticipa diseño instruccional para aprendizaje personalizado, porque cada evidencia debe traducirse en criterios comprensibles para docentes y responsables académicos.

Ese recorrido se sintetiza en la Figura 11, pensada para mostrar el flujo entre datos, interpretación y decisión.



**Figura 11.** Flujo de decisión para ciclo de vida de diseño, entrenamiento y validación.

En ciclo de vida de diseño, entrenamiento, validación y mejora, el gráfico puede mostrar un recorrido que comienza en diseño, incorpora los demás componentes del tema como criterios de interpretación y termina en mejora continua como decisión revisable. Conviene ubicar debajo una franja de mediación docente, seguimiento institucional y retroalimentación.

En ciclo de vida de diseño, entrenamiento, validación y mejora, con este marco, en síntesis, ciclo de vida de diseño, entrenamiento, validación y mejora aporta una condición de continuidad: permite pasar de la explicación conceptual a una decisión educativa que pueda discutirse, aplicarse y revisarse. Desde aquí se abre el paso hacia diseño instruccional para aprendizaje personalizado, donde esa condición se examina con otro grado de detalle.

Una vez definida la arquitectura, el paso siguiente consiste en revisar como se convierte en decisiones pedagógicas concretas.

## **Adaptación pedagógica, evaluación formativa y retroalimentación**

La cuarta sección lleva la arquitectura al terreno pedagógico. Un modelo híbrido solo adquiere sentido cuando mejora decisiones de diseño, evaluación, retroalimentación y acompañamiento. En esta parte, la pregunta no es si el sistema puede recomendar algo, sino si esa recomendación fortalece la experiencia formativa del estudiante.

### **4.1. Diseño instruccional para aprendizaje personalizado**

El tema anterior, centrado en ciclo de vida de diseño, entrenamiento, validación y mejora, abre una consecuencia práctica que ahora se desarrolla en diseño instruccional para aprendizaje personalizado. El paso natural consiste en pasar de una comprensión general a un criterio de actuación.

Antes de convertir diseño instruccional para aprendizaje personalizado en procedimiento, hace falta precisar qué problema educativo permite mirar con más cuidado. La discusión debe volver una y otra vez al estudiante y a la decisión educativa. Relacionar objetivos, contenidos, secuencias, actividades y evidencias con decisiones adaptativas exige separar la promesa tecnológica de la decisión educativa. Los datos pueden ampliar la mirada institucional, pero solo adquieren sentido cuando ayudan a comprender una necesidad, elegir una acción y revisar sus efectos. Esta lectura se sostiene en los aportes de Ifenthaler, Gibson y Dobozy y Khor y Mutthulakshmi [19], [20].

Al analizar diseño instruccional para aprendizaje personalizado, para avanzar, para que la exposición avance, conviene leer juntos objetivo, secuencia, actividad y evidencia. Objetivo no tiene valor aislado si no se relaciona con secuencia; Actividad muestra las condiciones de uso; y Evidencia convierte la información en una posibilidad de intervención.

Cuando diseño instruccional para aprendizaje personalizado pasa al plano institucional, para los equipos de gestión, diseño instruccional para aprendizaje personalizado plantea una exigencia concreta: transformar información dispersa en criterios compartidos. Si cada área interpreta objetivo de manera distinta, la respuesta vinculada con evidencia se vuelve irregular y difícil de evaluar.

Diseño instruccional para aprendizaje personalizado exige una cautela sencilla: ningún dato debe cerrar por sí solo la interpretación. El límite más delicado surge cuando la institución confunde predicción con destino. Una señal sobre objetivo puede advertir una dificultad, pero no autoriza a reducir la trayectoria del estudiante a una clasificación.

El razonamiento pasa ahora de la comprensión a la acción. Lo discutido aquí prepara rutas de aprendizaje adaptativas, donde la decisión necesita nuevos criterios y otra escala de análisis. La Tabla 12 separa la señal disponible, la lectura académica y el uso pedagógico posible.

**Tabla 12.** Criterios aplicados para diseño instruccional para aprendizaje personalizado.

Elemento de diseño	Evidencia requerida	Ajuste pedagógico posible
Objetivo de aprendizaje	Resultados esperados, competencias a desarrollar y nivel de logro que debe alcanzar el estudiante.	Precisar qué se debe reforzar, ampliar o reorganizar antes de proponer una actividad personalizada.
Secuencia didáctica	Orden de contenidos, prerrequisitos, progresión de dificultad y relación entre actividades.	Reorganizar el recorrido de aprendizaje según avances, vacíos conceptuales o necesidades detectadas.
Actividad de aprendizaje	Desempeño del estudiante, participación, errores frecuentes, tiempo de resolución y calidad de las respuestas.	Adaptar recursos, niveles de dificultad, consignas, tiempos o formas de acompañamiento.
Evidencia de aprendizaje	Productos, evaluaciones, retroalimentaciones, avances parciales y señales de mejora o dificultad.	Decidir si corresponde mantener la ruta, aplicar refuerzo, modificar la estrategia o activar seguimiento.

El cuadro ordena la decisión sin convertirla en receta; cada fila recuerda que el dato necesita interpretación antes de orientar una intervención. Esta precisión es fundamental porque el diseño instruccional para aprendizaje personalizado no consiste solamente en incorporar tecnología al proceso educativo, sino en organizar objetivos, actividades, recursos, evidencias y ajustes dentro de una lógica pedagógica coherente.

La evidencia ocupa un lugar inicial porque permite reconocer qué está ocurriendo en el proceso de aprendizaje. Sin embargo, su valor depende de la forma en que se

---

relaciona con los objetivos formativos. Una evidencia aislada puede mostrar un resultado, una dificultad o una señal de avance, pero no siempre explica por qué ocurre. Por ello, antes de modificar una actividad o proponer una ruta distinta, la institución debe revisar si la información disponible es suficiente y si se conecta con el propósito de aprendizaje que se desea alcanzar.

El indicador permite convertir esa evidencia en una señal más concreta. Puede estar asociado con desempeño, participación, avance, tiempo de respuesta, uso de recursos o cumplimiento de actividades. No obstante, el indicador no debe reemplazar la interpretación pedagógica. Su función es orientar la atención hacia una posible necesidad, no definir por sí solo la intervención.

La interpretación es el punto en el que el diseño instruccional adquiere sentido educativo. A partir de ella, el docente o el equipo académico decide si corresponde reforzar un contenido, cambiar la secuencia, ajustar una actividad, ampliar una explicación, ofrecer retroalimentación o activar acompañamiento. Sin esta lectura, la personalización puede convertirse en una respuesta automática que modifica recursos sin comprender la necesidad real del estudiante.

El ajuste pedagógico cierra el proceso porque transforma la información en acción. Este ajuste no debe entenderse como una corrección improvisada, sino como una decisión vinculada con objetivos, evidencias y criterios previamente definidos. Puede implicar cambios en el ritmo de aprendizaje, en la complejidad de las actividades, en el tipo de recurso, en la retroalimentación, en la evaluación o en el acompañamiento. Su pertinencia depende de que pueda justificarse, aplicarse y revisarse posteriormente.

Desde esta perspectiva, el diseño instruccional para aprendizaje personalizado solo tiene valor cuando mejora una decisión concreta y deja trazabilidad sobre sus efectos. No basta con adaptar contenidos o recomendar actividades; es necesario saber por qué se realiza el ajuste, qué evidencia lo sostiene, qué resultado se espera y cómo se verificará si produjo una mejora real en el aprendizaje.

Por ello, este apartado permite pasar de la comprensión general del modelo a una lógica de actuación pedagógica. La personalización se vuelve viable cuando el diseño

instruccional organiza la relación entre objetivos, indicadores, interpretación y ajuste. El apartado siguiente, dedicado a rutas de aprendizaje adaptativas, retoma esta misma preocupación desde una dimensión complementaria: cómo estructurar recorridos flexibles que respondan a diferentes trayectorias sin perder coherencia curricular ni responsabilidad institucional.

#### **4.2. Rutas de aprendizaje adaptativas**

Diseño instruccional para aprendizaje personalizado preparo el terreno para esta discusión. Ahora, rutas de aprendizaje adaptativas permite observar el mismo problema desde otro nivel de decisión.

Para un equipo académico, rutas de aprendizaje adaptativas se vuelve relevante cuando ayuda a elegir una acción y revisar sus consecuencias. Esta lectura ayuda a evitar una interpretación demasiado instrumental del problema. Explicar cómo se ajustan recorridos, ritmos, recursos y niveles según progreso y necesidades debe leerse como un problema de gestión pedagógica. El paso crítico no es registrar la señal, sino decidir cómo se acompaña al estudiante después de leerla. Los trabajos de Yuyón y Sueldo permiten ubicar esa relación entre evidencia y acción [5].

Al analizar rutas de aprendizaje adaptativas, la lectura gana claridad cuando la secuencia conceptual parte de ruta, pasa por ritmo y recurso, y desemboca en nivel de dificultad. Esa progresión evita que el apartado sea una enumeración y permite leer cada componente como parte de una decisión educativa mayor.

Como se observa en la Figura 12, el modelo requiere pasar por varias mediaciones antes de producir una recomendación útil.



**Figura 12.** Flujo de decisión para rutas de aprendizaje adaptativas.

En rutas de aprendizaje adaptativas, se recomienda representar tres capas: datos disponibles, interpretación pedagógica y respuesta institucional. Ruta inicia la lectura, mientras nivel de dificultad marca el punto donde la decisión debe documentarse y revisarse.

Para los equipos responsables, rutas de aprendizaje adaptativas exige asumir que el enfoque gerencial ayuda a ordenar responsabilidades.

La responsabilidad se reparte en tres momentos: selección de la señal, lectura de ritmo y comprobación de resultados en nivel de dificultad. La lectura de rutas de aprendizaje adaptativas pierde calidad cuando se separa del contexto académico y de la experiencia estudiantil. También existe un riesgo de exceso de confianza. Si el sistema presenta nivel de dificultad como solución evidente, puede ocultar condiciones que no están en los datos y que solo aparecen mediante diálogo pedagógico.

Este punto conecta hacia adelante porque ninguna arquitectura inteligente opera en el vacío. Lo que se define aquí como criterio volverá a aparecer en evaluación formativa mediada por datos como condición de aplicación. En este caso, la figura ayuda a ubicar entradas, mediaciones y salidas del sistema de forma más clara que una tabla.

---

En rutas de aprendizaje adaptativas, visto así, la idea que queda es prudente: el modelo híbrido ayuda si amplía la comprensión del aprendizaje, no si reemplaza el juicio académico por una clasificación rápida. Con esta base, evaluación formativa mediada por datos puede analizarse sin perder la relación entre datos, criterio y acción.

### **4.3. Evaluación formativa mediada por datos**

El recorrido no cambia de dirección; se vuelve más específico. Lo trabajado en rutas de aprendizaje adaptativas encuentra aquí, en evaluación formativa mediada por datos, una aplicación más concreta.

Para leer evaluación formativa mediada por datos con provecho, conviene pasar pronto de la categoría general a la situación que debe resolverse. El asunto se vuelve más claro cuando se observa el proceso completo. Analizar evidencias continuas, indicadores de avance y decisiones de mejora durante el proceso plantea una pregunta de fondo: que puede hacer mejor la institución cuando comprende el aprendizaje con mayor detalle. La respuesta no está en automatizar la decisión, sino en precisar que información ayuda, que límite tiene y como se traduce en apoyo. Khor y Mutthulakshmi y Hidalgo y Evans sirven aquí como referencias principales [20], [18].

El argumento avanza así de manera gradual: primero se delimita el problema, luego se precisan los componentes y después se abre el camino hacia retroalimentación inteligente y oportuna. En la Tabla 13, la lectura operativa queda concentrada en elementos que pueden discutirse antes de intervenir.

**Tabla 13.** Criterios aplicados para evaluación formativa mediada por datos.

Momento de evaluación	Pregunta formativa	Decisión de mejora
Recolección de evidencia	de ¿Qué señales muestran el avance, la dificultad o la participación del estudiante durante el proceso?	Identificar si existe una necesidad inicial de apoyo, refuerzo, retroalimentación o del seguimiento.
Lectura del indicador	¿El indicador muestra una señal parcial del desempeño?	Contrastar la información con otras evidencias reales antes de decidir una intervención.
Interpretación pedagógica	¿Qué puede explicar la dificultad observada, contenido, actividad, acceso, tiempo, retroalimentación o contexto?	Definir el tipo de apoyo más pertinente según la causa probable de la dificultad.
Ajuste formativo	¿Qué cambio puede mejorar el aprendizaje antes de cerrar la evaluación?	Modificar la actividad, reforzar contenidos, ampliar retroalimentación, flexibilizar tiempos o activar acompañamiento.

La síntesis separa el vocabulario técnico de la decisión pedagógica, una distinción necesaria para que el modelo no se limite a clasificar estudiantes. En la evaluación formativa mediada por datos, la información no tiene valor únicamente porque pueda registrarse o procesarse, sino porque permite comprender el aprendizaje mientras todavía es posible intervenir.

Esta condición diferencia la evaluación formativa de una lectura tardía del rendimiento: no se trata solo de conocer resultados, sino de actuar durante el proceso.

Al analizar evaluación formativa mediada por datos, el desarrollo del tema exige observar que los cuatro componentes del apartado cumplen funciones distintas. Evidencia orienta el diagnóstico inicial; Indicador ayuda a reconocer cambios; Interpretación protege la lectura contextual; y Ajuste pedagógico permite cerrar el circuito con una respuesta formativa.

Desde la coordinación académica, evaluación formativa mediada por datos se vuelve manejable cuando en una institución, evaluación formativa mediada por datos no

puede depender de intuiciones individuales ni de cálculos opacos. Necesita procedimientos claros, registros simples y espacios donde la evidencia se discuta antes de convertirse en decisión. El riesgo, en evaluación formativa mediada por datos, aparece cuando la institución actúa con más rapidez que criterio. Una lectura responsable debe reconocer que interpretación puede alterar el significado de cualquier indicador. Dos estudiantes con la misma señal pueden necesitar respuestas distintas.

La evidencia cumple una función inicial porque permite observar señales de avance, dificultad, participación o desempeño. Sin embargo, una evidencia aislada no debe convertirse de inmediato en una conclusión. Puede mostrar que un estudiante presenta bajo rendimiento en una actividad, que participa poco o que necesita más tiempo para completar una tarea, pero todavía hace falta interpretar qué significa esa señal dentro de su trayectoria. Por eso, la evidencia debe abrir una pregunta pedagógica antes de activar una respuesta.

El indicador ayuda a organizar esa evidencia y hacerla visible para docentes, tutores o equipos académicos. Puede mostrar tendencias, cambios en el desempeño, progresos parciales o alertas sobre posibles dificultades. No obstante, el indicador debe ser entendido como una señal orientadora, no como una explicación completa. Dos estudiantes pueden compartir el mismo indicador y requerir apoyos distintos, porque las causas de una dificultad no siempre aparecen en los datos disponibles.

La interpretación es el punto que protege el sentido formativo de la evaluación. A través de ella, la institución puede distinguir entre una dificultad conceptual, una barrera de acceso, una falta de retroalimentación, un problema de organización del tiempo o una necesidad de acompañamiento más cercana. Sin esta mediación, la evaluación mediada por datos corre el riesgo de producir respuestas automáticas, superficiales o poco pertinentes.

El ajuste pedagógico cierra el circuito porque transforma la lectura de datos en una acción educativa concreta. Este ajuste puede consistir en modificar una actividad, ofrecer retroalimentación adicional, proponer recursos complementarios, flexibilizar tiempos, reforzar un contenido o activar seguimiento tutorial. Lo importante es que

la decisión pueda justificarse con evidencia suficiente, explicarse de manera clara y revisarse posteriormente para verificar si tuvo efecto.

En evaluación formativa mediada por datos, el punto que conviene retener es este: toda personalización debe poder explicarse al estudiante, al docente y a la institución. Si la decisión no puede ser comprendida, discutida o corregida, pierde valor formativo, aunque esté respaldada por un sistema técnicamente avanzado. Por ello, la evaluación mediada por datos debe fortalecer la capacidad institucional para acompañar mejor, no para automatizar respuestas sin contexto.

El siguiente tema, retroalimentación inteligente y oportuna, permite continuar la secuencia y revisar nuevas implicaciones del modelo. Después de analizar cómo la evidencia y los indicadores pueden orientar ajustes durante el proceso, corresponde examinar cómo esa información se comunica al estudiante, en qué momento se entrega y bajo qué condiciones puede convertirse en una guía efectiva para mejorar el aprendizaje.

#### **4.4. Retroalimentación inteligente y oportuna**

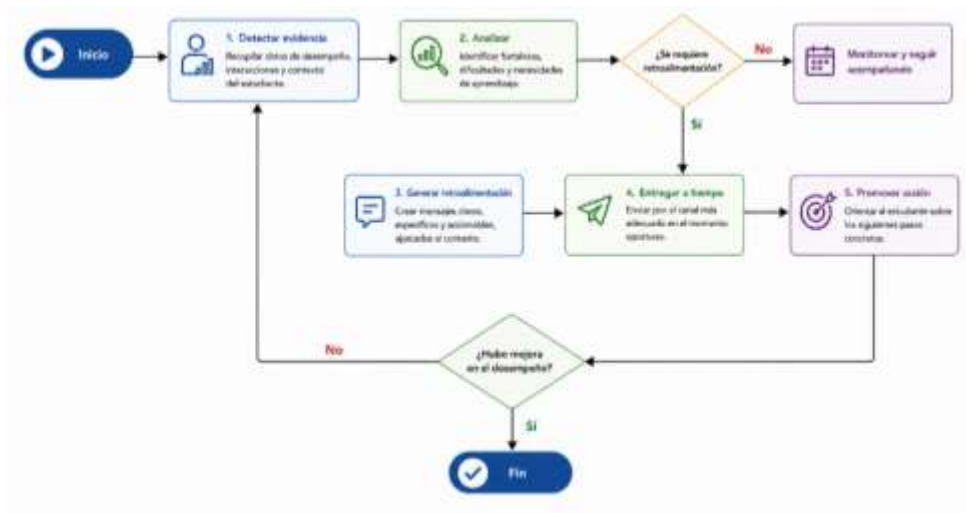
Para mantener el hilo del libro, retroalimentación inteligente y oportuna debe leerse como continuación de evaluación formativa mediada por datos. La diferencia está en el tipo de evidencia y en la responsabilidad que cada decisión activa.

Retroalimentación inteligente y oportuna gana claridad cuando se lo vincula con una decisión docente, institucional o de acompañamiento. Desde la gestión académica, la pregunta no es solo que puede medir el sistema. Estudiar retroalimentación automática, semiautomática y docente apoyada por datos requiere una lectura menos instrumental de la tecnología. Un sistema puede ordenar datos y sugerir rutas, aunque la pertinencia de esas rutas depende de su relación con objetivos, contexto y mediación docente. Esa cautela aparece en la discusión desarrollada por Jin et al. y Ifenthaler y Yau [21], [22].

Al analizar retroalimentación inteligente y oportuna, la exposición se ordena mejor si leídos en conjunto, mensaje, momento, acción sugerida y seguimiento forman una cadena de decisión. Primero aparece una señal, luego se interpreta su trayectoria, después se revisa el contexto y finalmente se define una acción que pueda ser observada y corregida.

La relación con el tema siguiente es práctica. Si retroalimentación inteligente y oportuna no se resuelve con claridad, tutores inteligentes y acompañamiento académico quedara apoyado sobre supuestos frágiles.

Para que el lector ubique la secuencia completa, la Figura 13 resume el flujo de decisión asociado con el tema.



**Figura 13.** Flujo de decisión para retroalimentación inteligente y oportuna.

En retroalimentación inteligente y oportuna, el esquema visual debe destacar que retroalimentación inteligente y oportuna no es una secuencia cerrada. Entre mensaje y seguimiento deben aparecer puntos de validación académica, revisión de contexto y ajuste de la intervención.

En la gestión de retroalimentación inteligente y oportuna, la utilidad del modelo se mide en la coordinación que produce. Cuando docencia, bienestar, tecnología y dirección curricular trabajan con el mismo criterio, mensaje deja de ser un dato suelto y se vuelve parte de una estrategia. La precaución básica en retroalimentación inteligente y oportuna consiste en no confundir señal con explicación suficiente. El problema no está en usar datos, sino en usarlos sin contexto. Cuando momento se interpreta sin mediación, el modelo puede producir decisiones ordenadas, aunque pedagógicamente pobres.

En retroalimentación inteligente y oportuna, la consecuencia para el libro es clara: visto en conjunto, retroalimentación inteligente y oportuna fortalece la obra porque conecta datos, mediación y seguimiento dentro de una misma lógica de responsabilidad. A partir de este punto, tutores inteligentes y acompañamiento académico aparece como una consecuencia natural del argumento.

#### **4.5. Tutores inteligentes y acompañamiento académico**

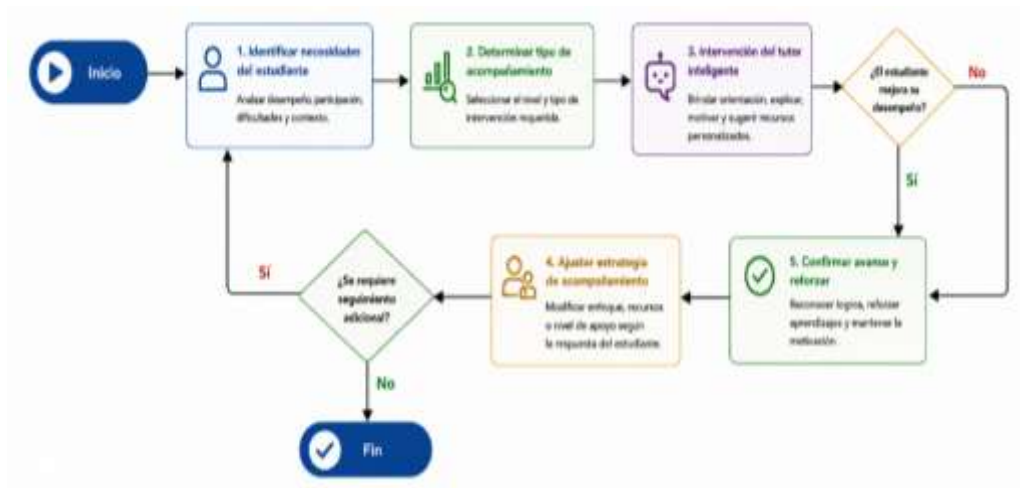
El paso desde retroalimentación inteligente y oportuna hacia tutores inteligentes y acompañamiento académico permite afinar el argumento. Ya no se trata solo de reconocer el problema, sino de establecer como puede gestionarse.

El interés de tutores inteligentes y acompañamiento académico está en mostrar qué puede hacerse distinto dentro de la experiencia formativa. En este punto, la tecnología debe leerse como parte de una decisión mayor. Presentar sistemas de tutoría, orientación personalizada, diálogo educativo y apoyo escalable se vuelve útil cuando conecta información disponible con decisiones que alguien puede explicar. Si la institución no sabe por qué actúa, el modelo pierde valor pedagógico, aunque funcione técnicamente. Ese equilibrio debe quedar respaldado por evidencia textual antes de transformarse en una afirmación citada.

Conviene sostener una reserva básica: tutores inteligentes y acompañamiento académico orienta decisiones, pero no cierra por sí solo la interpretación. La automatización resulta útil mientras conserve puntos de revisión. Si una recomendación sobre escalabilidad no puede explicarse, discutirse o corregirse, el sistema pierde legitimidad educativa.

Este apartado funciona como bisagra dentro del capítulo. Recoge lo anterior, ordena sus implicaciones y deja planteada la necesidad de revisar adaptación de recursos, actividades y niveles de dificultad.

El proceso descrito puede representarse en la Figura 14, donde la mediación académica aparece como parte del sistema y no como un agregado externo.



**Figura 14.** Flujo de decisión para tutores inteligentes y acompañamiento académico.

En tutores inteligentes y acompañamiento académico, una opción clara es usar un diagrama de flujo con cuatro nodos principales. El primer nodo corresponde a tutor inteligente; el último a escalabilidad; entre ambos se ubican los criterios que permiten pasar de observación a decisión.

Con este esquema, el lector puede observar el movimiento del modelo y no solo sus componentes separados. En tutores inteligentes y acompañamiento académico, en términos pedagógicos, el cierre operativo es claro: una decisión personalizada necesita evidencia suficiente, criterio pedagógico y posibilidad de corrección. La discusión queda preparada para avanzar hacia adaptación de recursos, actividades y niveles de dificultad, sin romper el hilo pedagógico de la obra.

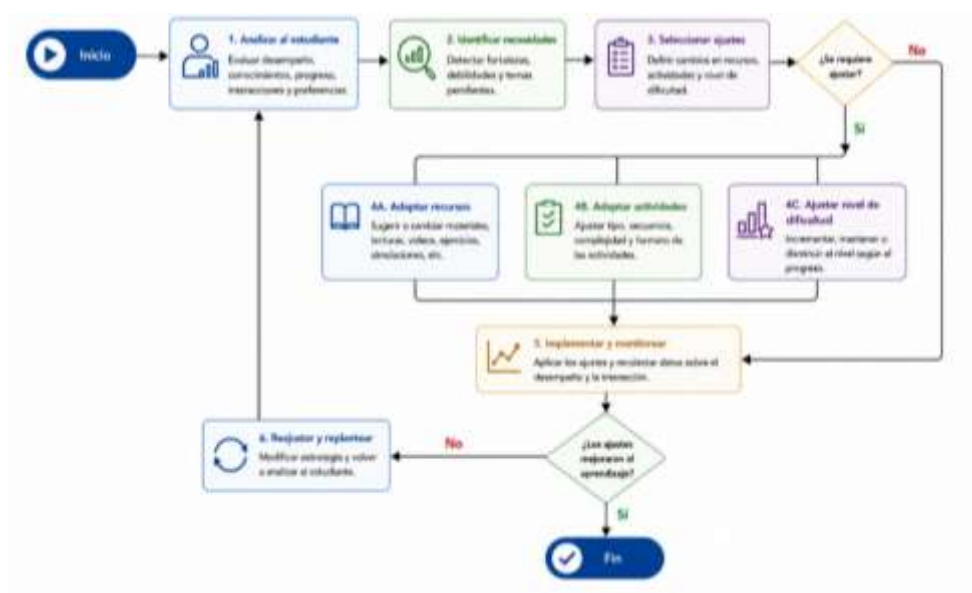
#### **4.6. Adaptación de recursos, actividades y niveles de dificultad**

La sección avanza de manera acumulativa. Tutores inteligentes y acompañamiento académico dejó planteado un límite; adaptación de recursos, actividades y niveles de dificultad examina una forma de responderlo.

Para leer adaptación de recursos, actividades y niveles de dificultad con provecho, conviene pasar pronto de la categoría general a la situación que debe resolverse. Una lectura responsable comienza por reconocer los límites del dato disponible. Examinar criterios para seleccionar materiales, retos, prácticas y apoyos diferenciados no puede reducirse a una operación técnica. Implica reconocer condiciones de aprendizaje, valorar evidencias parciales y decidir apoyos que no cierren la trayectoria del estudiante de antemano. Las referencias de Pan et al. y Ifenthaler, Gibson y Dobozy permiten sostener esa interpretación [23], [19].

Al analizar adaptación de recursos, actividades y niveles de dificultad, la relación interna del tema muestra que el apartado gana fuerza cuando recurso, actividad, reto y apoyo diferenciado se leen como partes de un mismo proceso. Cada elemento aporta una pregunta distinta, y la suma de esas preguntas ayuda a construir una intervención más responsable.

Desde la coordinación académica, adaptación de recursos se vuelve manejable cuando actividades y niveles de dificultad, el valor institucional aparece cuando la lectura de recurso ayuda a actuar con oportunidad. La Figura 15 muestra ese recorrido sin sugerir que la respuesta educativa salga de forma automática.



**Figura 15.** Flujo de decisión para adaptación de recursos, actividades y niveles de dificultad.

En adaptación de recursos, actividades y niveles de dificultad, la representación puede mostrar una ruta de decisión acompañada por dos controles transversales: responsabilidad pedagógica y protección de datos. Estos controles atraviesan el proceso desde recurso hasta apoyo diferenciado.

La figura concentra el sentido operativo del apartado: como una señal se transforma en interpretación y luego en acción. En adaptación de recursos, actividades y niveles de dificultad, el aporte del apartado puede resumirse así: este apartado deja una advertencia útil: la sofisticación técnica no compensa una lectura pobre del contexto educativo. El lector puede pasar ahora a rol docente en sistemas de personalización inteligente con una pregunta más precisa sobre el uso responsable de la personalización.

#### **4.7. Rol docente en sistemas de personalización inteligente**

Antes de entrar en rol docente en sistemas de personalización inteligente, conviene recordar el punto previo: adaptación de recursos, actividades y niveles de dificultad. Esa referencia evita que el nuevo tema aparezca como bloque aislado.

Antes de convertir rol docente en sistemas de personalización inteligente en procedimiento, hace falta precisar qué problema educativo permite mirar con más

cuidado. El tema gana sentido cuando se conecta con prácticas concretas de acompañamiento. Reafirmar mediación docente, juicio pedagógico, interpretación de datos y responsabilidad académica introduce un criterio práctico para la Educación Superior: usar tecnología solo cuando mejora la comprensión del proceso formativo. Los indicadores, por sí solos, no enseñan; orientan cuando se insertan en una decisión pedagógica clara. Esa perspectiva dialoga con Ifenthaler y Yau y Guzmán-Valenzuela et al. [22], [9].

Al analizar rol docente en sistemas de personalización inteligente, para evitar una lectura fragmentada, en lugar de tratar mediación, juicio pedagógico, interpretación de datos y responsabilidad como definiciones cerradas, este capítulo los usa como puntos de observación. Cada punto permite examinar que sabe la institución, que no sabe todavía y que decisión sería prudente antes de avanzar.

El modo en que estos elementos se traducen en decisiones se aprecia en la Tabla 14.

**Tabla 14.** Criterios aplicados para rol docente en sistemas de personalización inteligente.

<b>Función docente</b>	<b>Aporte al modelo</b>	<b>Responsabilidad asociada</b>
Mediación pedagógica	Conecta la recomendación del sistema con la realidad del aula, la asignatura y la trayectoria del estudiante.	Evitar que la decisión se aplique de forma automática sin considerar contexto, condiciones y necesidades reales.
Juicio pedagógico	Permite valorar si una alerta, indicador o recomendación tiene sentido educativo.	Decidir si corresponde intervenir, ajustar, esperar más evidencia o derivar el caso a otra instancia de apoyo.
Interpretación de datos	Traduce la información del modelo en una lectura comprensible para la acción docente e institucional.	Reconocer límites del dato, contrastar evidencias y evitar conclusiones apresuradas sobre el estudiante.
Responsabilidad académica	Define quién valida, aplica, comunica y revisa las decisiones derivadas del sistema.	Garantizar que toda intervención sea explicable, corregible y orientada al aprendizaje, no solo a la clasificación.

El cuadro invita a una lectura deliberativa; ayuda a conversar sobre el modelo sin sustituir la discusión académica que toda personalización requiere.

Esta precisión es fundamental porque el rol docente en sistemas de personalización inteligente no desaparece con la incorporación de tecnología; por el contrario, se vuelve más relevante. Cuando los sistemas producen alertas, recomendaciones o

trayectorias posibles, el docente cumple la función de interpretar, contextualizar y decidir si esa información realmente corresponde con la situación educativa observada.

La mediación docente permite que la personalización no se reduzca a una respuesta automática. El docente conoce el desarrollo de la asignatura, las condiciones del grupo, las dificultades frecuentes, los ritmos de aprendizaje y las características del proceso formativo. Ese conocimiento situado ayuda a valorar si una recomendación del sistema es pertinente, si necesita ajustes o si debe descartarse por no representar adecuadamente la realidad del estudiante.

El juicio pedagógico aporta el criterio necesario para distinguir entre una señal útil y una interpretación insuficiente. Un indicador puede mostrar baja participación, retraso en actividades o dificultad en una evaluación, pero el docente debe analizar qué factores pueden explicar esa situación. La causa puede estar en una barrera de acceso, una dificultad conceptual, una falta de retroalimentación, una sobrecarga académica o una condición personal que el sistema no registra. Por eso, el juicio docente protege al estudiante de decisiones apresuradas o reduccionistas.

La interpretación de datos exige también responsabilidad académica. No basta con recibir información del sistema; es necesario comprender qué significa, qué límites tiene y qué consecuencias puede producir. Una recomendación mal interpretada puede reforzar desigualdades, etiquetar al estudiante o activar apoyos que no corresponden a su necesidad real. En cambio, una interpretación responsable permite convertir los datos en oportunidades de acompañamiento, retroalimentación y mejora.

La responsabilidad docente e institucional cierra este proceso. Personalizar no significa trasladar la decisión al sistema, sino organizar mejor la información para tomar decisiones más justificadas. La institución debe definir quién revisa las alertas, cómo se valida una recomendación, qué margen tiene el docente para corregirla y cómo se evalúan los efectos de la intervención. Sin estas condiciones, la personalización inteligente corre el riesgo de convertirse en una práctica opaca, difícil de explicar y débil en términos pedagógicos.

En rol docente en sistemas de personalización inteligente, la conclusión parcial es que el valor del modelo depende de su capacidad para fortalecer la mediación, no para reemplazarla. Un sistema inteligente puede ampliar la observación, ordenar evidencias y sugerir rutas, pero la decisión educativa requiere criterio, contexto y responsabilidad humana.

Por ello, el rol docente debe evaluarse por su aporte al aprendizaje y por la calidad de las decisiones que permite sostener.

Esa idea conduce a retención académica, permanencia y riesgo de abandono, donde el problema vuelve a formularse desde otra responsabilidad institucional. Si los sistemas de personalización ayudan a detectar señales de riesgo, el papel docente e institucional será decisivo para convertir esas señales en acompañamiento oportuno, acciones preventivas y estrategias de permanencia. Estas aplicaciones muestran que la personalización debe evaluarse también por sus efectos institucionales, éticos y de continuidad educativa.

## **Retención académica, ética de datos y prospectiva tecnológica**

La quinta sección examina las consecuencias institucionales y éticas. La personalización inteligente puede contribuir a la permanencia, al seguimiento temprano y a la mejora de programas; sin embargo, también exige privacidad, transparencia, aplicabilidad, gobernanza y evaluación de impacto. Sin esas condiciones, la innovación pierde legitimidad.

### **5.1. Retención académica, permanencia y riesgo de abandono**

Retención académica, permanencia y riesgo de abandono recoge una inquietud que ya estaba presente en rol docente en sistemas de personalización inteligente. La obra mantiene así una progresión entre contexto, evidencia y acción.

Retención académica, permanencia y riesgo de abandono gana claridad cuando se lo vincula con una decisión docente, institucional o de acompañamiento. Para una institución, la diferencia entre información y decisión es decisiva. Relacionar personalización inteligente con identificación temprana de dificultades y apoyo a la permanencia debe vincularse con la capacidad institucional de actuar a tiempo. Observar el aprendizaje demasiado tarde convierte la analítica en registro; observarlo con criterio permite ofrecer apoyo antes de que la dificultad se consolide. Este punto se apoya en Verdal et al. y Waddington et al. [24], [15].

Al analizar retención académica, permanencia y riesgo de abandono, el análisis se sostiene cuando la relación entre permanencia y apoyo oportuno organiza el sentido del apartado. Entre ambos se ubican riesgo y compromiso, que permiten pasar de la información inicial a una lectura situada del proceso de aprendizaje.

En la gestión de retención académica, permanencia y riesgo de abandono, una decisión bien administrada combina evidencia, criterio y seguimiento. En este tema, eso significa que riesgo debe dialogar con compromiso antes de activar una respuesta sobre apoyo oportuno.

La precaución básica en retención académica, permanencia y riesgo de abandono consiste en no confundir señal con explicación suficiente. Una dificultad frecuente consiste en actuar demasiado rápido. Antes de convertir riesgo en intervención, la

institución debe revisar si la evidencia es suficiente y si la respuesta no agrava desigualdades previas.

La conexión con sistemas de alerta temprana y acompañamiento institucional muestra que cada decisión educativa necesita una base anterior. La Tabla 15 sirve como pausa de organización: obliga a mirar el criterio antes de pasar a la decisión.

**Tabla 15.** Criterios aplicados para retención académica, permanencia y riesgo de abandono.

Señal de permanencia	Interpretación institucional	Apoyo oportuno
Compromiso académico	Permite observar la relación del estudiante con actividades, asistencia, participación, entregas y continuidad en el proceso formativo.	Activar seguimiento docente o cuando se identifique disminución sostenida del compromiso.
Riesgo de abandono	Funciona como alerta temprana, pero no debe interpretarse como destino académico ni como explicación suficiente.	Contrastar la señal con evidencias académicas, personales, tecnológicas o institucionales antes de intervenir.
Permanencia	Muestra si el estudiante cuenta con condiciones para continuar su trayectoria formativa de manera sostenida.	Diseñar apoyos diferenciados: académico, acompañamiento, flexibilización, orientación o derivación institucional.
Continuidad formativa	Permite revisar si las acciones de participación, el avance y la permanencia del estudiante.	Mantener, ajustar o cerrar el apoyo producen efecto en la evolución según la observada después de la intervención.

La matriz permite reconocer dónde termina la observación y dónde empieza la responsabilidad institucional. Esta diferencia es especialmente importante en retención académica, permanencia y riesgo de abandono, porque las señales tempranas no deben convertirse automáticamente en decisiones sobre el estudiante. Un indicador puede advertir una posible dificultad, pero la institución necesita interpretar esa señal con cuidado antes de intervenir.

La retención académica no debe entenderse solo como la capacidad de mantener estudiantes matriculados. También implica crear condiciones para que puedan avanzar, participar, superar dificultades y completar su trayectoria formativa con apoyos adecuados. Desde esta perspectiva, la permanencia no depende únicamente del esfuerzo individual del estudiante, sino también de la capacidad institucional para identificar barreras, responder a tiempo y sostener procesos de acompañamiento.

El riesgo de abandono funciona como una señal inicial, no como una conclusión definitiva.

Puede estar asociado con bajo rendimiento, inasistencia, escasa participación, retraso en actividades, dificultades económicas, problemas de acceso, desmotivación o falta de acompañamiento.

Ninguna de estas señales explica por sí sola la situación completa. Por ello, antes de activar una intervención, la institución debe revisar si cuenta con evidencia suficiente y si la respuesta propuesta es proporcional, pertinente y respetuosa.

El compromiso del estudiante permite ampliar esta lectura. No se expresa únicamente en calificaciones o asistencia, sino también en la forma en que participa, solicita apoyo, responde a la retroalimentación, mantiene continuidad y se vincula con su proceso formativo. Un modelo híbrido puede ayudar a identificar cambios en ese compromiso, pero la interpretación debe mantenerse abierta. Una disminución en la participación puede ser una alerta académica, pero también puede responder a condiciones personales, laborales, familiares o tecnológicas.

El apoyo oportuno cierra el circuito porque transforma la información en una acción institucional concreta. Este apoyo puede tomar distintas formas: tutoría académica, seguimiento docente, flexibilización temporal, refuerzo de contenidos, orientación psicoeducativa, derivación a bienestar estudiantil o revisión de condiciones de acceso. Lo importante es que la intervención no sea genérica, sino vinculada con la necesidad identificada y con la posibilidad real de acompañar al estudiante.

En este punto, la ética de datos adquiere relevancia directa. Aunque el apartado se centre en retención y permanencia, toda acción basada en información estudiantil debe considerar consentimiento, finalidad, minimización y responsabilidad. La institución debe tener claridad sobre qué datos utiliza, para qué los utiliza, quién los interpreta, cómo se protege la información y qué consecuencias puede generar una recomendación. Sin estas condiciones, el seguimiento temprano puede convertirse en vigilancia o clasificación injustificada.

En retención académica, permanencia y riesgo de abandono, la conclusión parcial debe mantenerse prudente: personalizar significa acompañar mejor, no automatizar

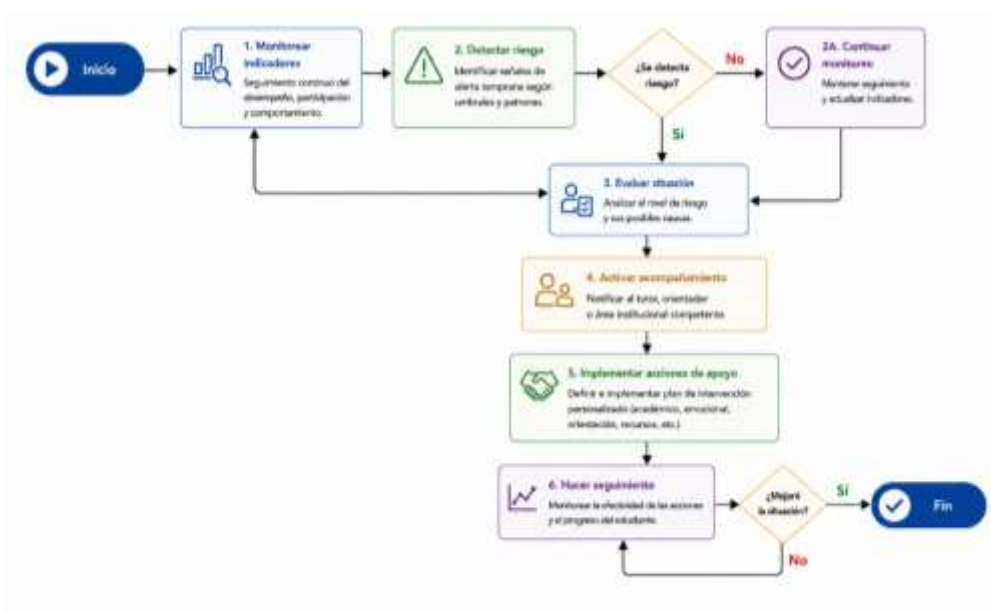
más. La detección temprana solo tiene sentido si conduce a apoyos explicables, revisables y orientados al bienestar académico del estudiante. Lo desarrollado aquí se completa en sistemas de alerta temprana y acompañamiento institucional, que desplaza la atención hacia el siguiente nivel del sistema: cómo organizar alertas, responsables, protocolos y acciones de seguimiento sin perder el criterio pedagógico ni la responsabilidad ética.

### **5.2. Sistemas de alerta temprana y acompañamiento institucional**

El apartado se apoya en lo discutido sobre retención académica, permanencia y riesgo de abandono, pero desplaza la atención hacia sistemas de alerta temprana y acompañamiento institucional. Ese desplazamiento permite precisar mejor las condiciones de uso del modelo híbrido.

Antes de convertir sistemas de alerta temprana y acompañamiento institucional en procedimiento, hace falta precisar qué problema educativo permite mirar con más cuidado. El enfoque resulta más sólido cuando combina claridad conceptual y prudencia operativa. Analizar indicadores, protocolos, intervención académica y seguimiento de estudiantes en riesgo invita a mirar el modelo como una herramienta de deliberación. La recomendación automatizada puede ser un insumo, pero la decisión final necesita contexto, conversación académica y seguimiento. Los aportes de Waddington et al. y Hidalgo y Evans ayudan a delimitar ese uso [15], [18].

La Figura 16 permite mostrar las capas que median entre el dato inicial y la acción sugerida.



**Figura 16.** Flujo de decisión para sistemas de alerta temprana y acompañamiento institucional.

En sistemas de alerta temprana y acompañamiento institucional, el recurso visual debe hacer visible la mediación humana. Aunque el flujo parta de alerta y llegue a seguimiento, conviene incluir puntos donde docentes, estudiantes o equipos académicos puedan validar la interpretación.

Al analizar sistemas de alerta temprana y acompañamiento institucional, la decisión educativa se entiende mejor si el recorrido conceptual se sostiene en cuatro piezas: alerta, protocolo, intervención y seguimiento. La primera permite iniciar el diagnóstico; la segunda muestra movimiento; la tercera incorpora condiciones reales; y la cuarta exige transformar el análisis en apoyo.

Cuando sistemas de alerta temprana y acompañamiento institucional pasa al plano institucional, el modelo híbrido funciona como apoyo cuando permite que distintas áreas miren el mismo caso con lenguaje común. Así, alerta no se interpreta de forma aislada y seguimiento puede planificarse con mayor coherencia.

Sistemas de alerta temprana y acompañamiento institucional exige una cautela sencilla: ningún dato debe cerrar por sí solo la interpretación. El uso responsable implica conservar una puerta de salida. Si el análisis sobre alerta no describe bien la situación, el estudiante y el docente deben tener formas claras de corregir la lectura.

El hilo conductor permanece: comprender mejor al estudiante para decidir mejor. Desde aquí, ética de datos en modelos inteligentes educativos aparece como el siguiente nivel de esa misma discusión.

El resultado es una lectura aplicada del tema, orientada a decisiones que puedan sostenerse pedagógica y éticamente. Por esa razón, ética de datos en modelos inteligentes educativos no aparece como tema separado, sino como continuación del mismo proceso de decisión.

### **5.3. *Ética de datos en modelos inteligentes educativos***

Después de revisar sistemas de alerta temprana y acompañamiento institucional, el análisis avanza hacia ética de datos en modelos inteligentes educativos. El apartado anterior deja una condición de trabajo y esta muestra como esa condición se convierte en una decisión más precisa.

El valor de ética de datos en modelos inteligentes educativos aparece cuando deja de ser una categoría general y empieza a ordenar una acción. La discusión requiere una mirada doble: pedagógica e institucional. Revisar consentimiento, finalidad, proporcionalidad, minimización y responsabilidad en el uso de datos no significa agregar una herramienta a un curso ni acumular indicadores en una plataforma. La institución necesita separar tres tareas: observar una señal, interpretarla con criterio y convertirla en apoyo oportuno. En ese marco, Cornac y Retos, Heródoto y Gillespie ofrecen una base para tratar el tema con prudencia académica [25], [26].

Al analizar ética de datos en modelos inteligentes educativos, en este punto, el tema se articula mediante consentimiento, finalidad, minimización y responsabilidad. Consentimiento abre la lectura del problema; Finalidad permite seguir su evolución; Minimización introduce el contexto donde la decisión toma forma; y Responsabilidad obliga a precisar que acción puede mejorar el aprendizaje.

En condiciones reales, ética de datos en modelos inteligentes educativos muestra que, desde una mirada de administración académica, ética de datos en modelos inteligentes educativos debe evaluarse por las decisiones que habilita. Un dato sobre consentimiento puede orientar una ruta, pero no debería cerrar la interpretación.

También puede requerir contraste con docentes, historiales, condiciones de acceso y resultados previos.

El punto delicado en ética de datos en modelos inteligentes educativos está en conservar margen para revisar la recomendación del sistema. El riesgo aparece cuando consentimiento se convierte en etiqueta y responsabilidad se transforma en respuesta automática. Por eso conviene trabajar con criterios explícitos y con mecanismos de corrección, no con clasificaciones cerradas.

En la implementación, este apartado retoma el problema anterior y lo vuelve más operativo. También anticipa privacidad, transparencia, aplicabilidad y sesgos algorítmicos, porque cada evidencia debe traducirse en criterios comprensibles para docentes y responsables académicos. Esta relación entre evidencia y acción se muestra en la Tabla 16.

**Tabla 16.** Criterios aplicados para ética de datos en modelos inteligentes educativos.

Principio ético	Pregunta de control	Responsabilidad institucional
Consentimiento	¿El estudiante conoce qué datos se recopilan, para qué se usan y cómo pueden influir en decisiones de acompañamiento?	Garantizar información clara, comprensible y actualizada sobre el uso de datos dentro del modelo educativo.
Finalidad	¿El uso de los datos responde a un propósito pedagógico legítimo y previamente definido?	Evitar que la información estudiantil se utilice para fines distintos a los comunicados o sin justificación educativa.
Minimización	¿La institución está usando solo los datos necesarios para comprender la situación y orientar una decisión?	Reducir la recolección excesiva de información y proteger al estudiante frente a usos innecesarios o desproporcionados.
Responsabilidad	¿Quién interpreta, valida, comunica y corrige las decisiones apoyadas por el modelo?	Definir responsables, procedimientos de revisión y mecanismos de corrección ante errores, sesgos o decisiones injustificadas.

La lectura del cuadro permite pasar de la definición a la decisión, porque cada elemento queda asociado con una evidencia, un criterio y una responsabilidad. Esta relación es fundamental porque la ética de datos en modelos inteligentes educativos no puede limitarse a una declaración general de buenas intenciones. Su valor aparece cuando orienta decisiones concretas sobre qué datos se usan, con qué propósito, bajo qué condiciones y con qué consecuencias para el estudiante.

El consentimiento constituye un punto de partida necesario. La institución debe asegurar que el estudiante comprenda qué información se recopila, para qué se utiliza y cómo puede incidir en procesos de seguimiento, recomendación o acompañamiento. Sin embargo, el consentimiento no debe tratarse como un trámite formal que autoriza cualquier uso posterior. Debe mantenerse vinculado con información clara, actualizada y comprensible sobre el funcionamiento del modelo y sus posibles efectos educativos.

La finalidad permite delimitar el uso legítimo de los datos. No toda información disponible debe ser utilizada, ni todo dato recogido para un propósito puede trasladarse automáticamente a otro. En un modelo inteligente educativo, la finalidad debe estar asociada con el mejoramiento del aprendizaje, el acompañamiento oportuno, la detección de necesidades o la mejora institucional. Cuando la finalidad no está claramente definida, aumenta el riesgo de vigilancia, clasificación excesiva o uso de información sin justificación pedagógica suficiente.

La minimización introduce un criterio de prudencia. La institución debe recoger y procesar solo los datos necesarios para cumplir una finalidad educativa explícita. Este principio ayuda a evitar la acumulación indiscriminada de información y protege al estudiante frente a usos innecesarios o desproporcionados. En términos pedagógicos, minimización significa reconocer que más datos no siempre producen mejores decisiones; lo importante es contar con información pertinente, interpretable y suficiente.

La responsabilidad cierra el circuito ético porque obliga a definir quién responde por las decisiones que el modelo informa o sugiere. Un sistema puede generar alertas, perfiles o recomendaciones, pero la institución debe establecer quién las revisa, cómo se validan, qué margen existe para corregirlas y cómo se comunican al estudiante. Sin responsables definidos, la automatización puede diluir la rendición de cuentas y dificultar la corrección de errores.

En ética de datos en modelos inteligentes educativos, la síntesis debe mantenerse clara: el uso de datos solo tiene legitimidad cuando mejora el acompañamiento educativo sin debilitar los derechos, la dignidad ni la autonomía del estudiante. Por

ello, todo modelo inteligente debe operar con criterios explícitos, procedimientos verificables y espacios de revisión humana. La ética no aparece después de la tecnología; debe formar parte del diseño, la implementación y la evaluación del sistema.

Con este marco, la ética de datos aporta una condición de continuidad para la obra: permite pasar de la explicación conceptual a una decisión educativa que pueda discutirse, aplicarse y revisarse. Desde aquí se abre el paso hacia privacidad, transparencia, aplicabilidad y sesgos algorítmicos, donde esa condición se examina con mayor detalle. En ese siguiente nivel, el análisis deberá precisar cómo se protege la información, cómo se explican las decisiones del modelo y cómo se previenen efectos injustos derivados de datos incompletos, sesgados o mal interpretados.

#### **5.4. Privacidad, transparencia, aplicabilidad y sesgos algorítmicos**

El tema anterior, centrado en ética de datos en modelos inteligentes educativos, abre una consecuencia práctica que ahora se desarrolla en privacidad, transparencia, aplicabilidad y sesgos algorítmicos. El paso natural consiste en pasar de una comprensión general a un criterio de actuación.

Para leer privacidad, transparencia, aplicabilidad y sesgos algorítmicos con provecho, conviene pasar pronto de la categoría general a la situación que debe resolverse. Aquí conviene evitar respuestas rápidas y revisar primero el proceso completo. Examinar riesgos técnicos y éticos asociados con decisiones automatizadas o semiautomatizadas exige separar la promesa tecnológica de la decisión educativa. Los datos pueden ampliar la mirada institucional, pero solo adquieren sentido cuando ayudan a comprender una necesidad, elegir una acción y revisar sus efectos. Esta lectura se sostiene en los aportes de Heimlich, Gzebos y Drachsler y Cormack [27], [25].

Al analizar privacidad, transparencia, explicabilidad y sesgos algorítmicos, para avanzar, para que la exposición avance, conviene leer juntos privacidad, transparencia, explicabilidad y sesgo. Privacidad no tiene valor aislado si no se relaciona con transparencia; Explicabilidad muestra las condiciones de uso; y Sesgo convierte la información en una posibilidad de intervención.

Lo discutido aquí prepara gobernanza institucional de la inteligencia artificial educativa, donde la decisión necesita nuevos criterios y otra escala de análisis. La Tabla 17 separa la señal disponible, la lectura académica y el uso pedagógico posible.

**Tabla 17.** Criterios aplicados para privacidad, transparencia, explicabilidad y sesgos algorítmicos.

Señal de permanencia	Interpretación institucional	Apoyo oportuno
Compromiso académico	Permite observar la relación del estudiante con actividades, cuando se identifique asistencia, participación, entregas sostenidas y continuidad en el proceso formativo.	Activar seguimiento docente o tutorial de disminución del compromiso.
Riesgo de abandono	Funciona como alerta temprana, pero no debe interpretarse como académicas, personales, tecnológicas o destino académico ni como institucionales antes de intervenir. explicación suficiente.	Contrastar la señal con evidencias académicas, personales, tecnológicas o institucionales antes de intervenir.
Permanencia	Muestra si el estudiante cuenta con condiciones para continuar su trayectoria formativa de manera sostenida.	Diseñar apoyos diferenciados: refuerzo académico, acompañamiento, flexibilización, orientación o derivación institucional.

El cuadro ordena la decisión sin convertirla en receta; cada fila recuerda que el dato necesita interpretación antes de orientar una intervención. Desde la coordinación académica, privacidad se vuelve manejable cuando transparencia, explicabilidad y sesgos algorítmicos, para los equipos de gestión, privacidad, transparencia, explicabilidad y sesgos algorítmicos plantea una exigencia concreta: transformar información dispersa en criterios compartidos. Si cada área interpreta privacidad de manera distinta, la respuesta vinculada con sesgo se vuelve irregular y difícil de evaluar.

El riesgo, en privacidad, transparencia, explicabilidad y sesgos algorítmicos, aparece cuando la institución actúa con más rapidez que criterio. El límite más delicado surge cuando la institución confunde predicción con destino. Una señal sobre privacidad puede advertir una dificultad, pero no autoriza a reducir la trayectoria del estudiante a una clasificación.

En privacidad, transparencia, explicabilidad y sesgos algorítmicos, desde esta perspectiva, el aprendizaje principal del apartado es que privacidad, transparencia,

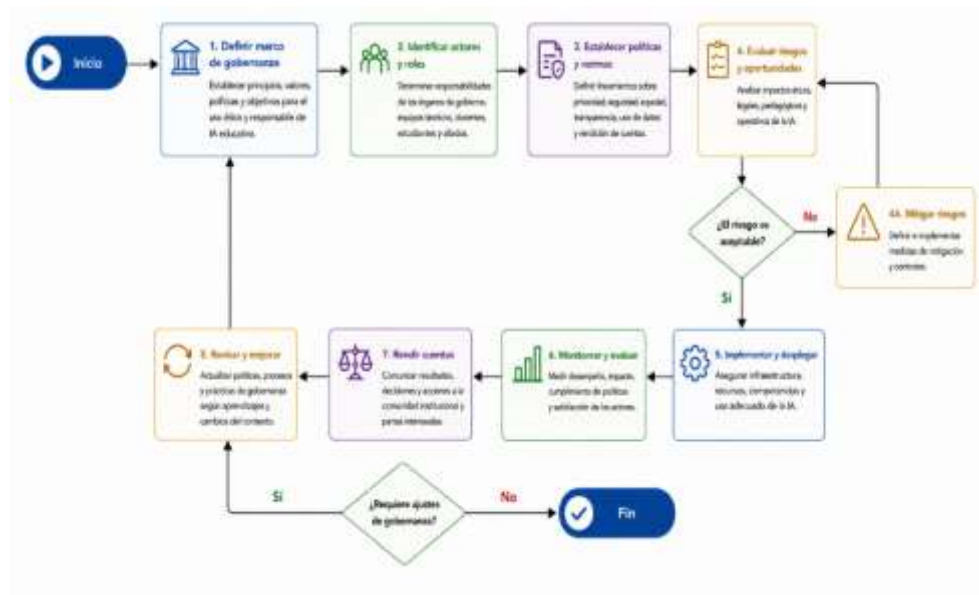
explicabilidad y sesgos algorítmicos solo tiene valor cuando mejora una decisión concreta y deja trazabilidad sobre sus efectos. El apartado siguiente, dedicado a gobernanza institucional de la inteligencia artificial educativa, retoma esta misma preocupación desde una dimensión complementaria.

### **5.5. Gobernanza institucional de la inteligencia artificial educativa**

Privacidad, transparencia, explicabilidad y sesgos algorítmicos preparó el terreno para esta discusión. Ahora, gobernanza institucional de la inteligencia artificial educativa permite observar el mismo problema desde otro nivel de decisión.

Gobernanza institucional de la inteligencia artificial educativa gana claridad cuando se lo vincula con una decisión docente, institucional o de acompañamiento. La utilidad del modelo depende de la calidad de la pregunta que intenta resolver. Proponer políticas, roles, comités, auditoría, gestión de riesgos y rendición de cuentas debe leerse como un problema de gestión pedagógica. La detección gana valor cuando permite definir quién actúa, con qué información y bajo qué límite. Los trabajos de Elouazizi y Sclater permiten ubicar esa relación entre evidencia y acción [28], [29], [30].

Como se muestra en la Figura 17, el modelo requiere pasar por varias mediaciones antes de producir una recomendación útil.



**Figura 17.** Flujo de decisión para gobernanza institucional de la inteligencia artificial educativa.

En gobernanza institucional de la inteligencia artificial educativa, se recomienda representar tres capas: datos disponibles, interpretación pedagógica y respuesta institucional. Política inicia la lectura, mientras rendición de cuentas marca el punto donde la decisión debe documentarse y revisarse.

Al analizar gobernanza institucional de la inteligencia artificial educativa, la lectura gana claridad cuando la secuencia conceptual parte de política, pasa por rol institucional y auditoría, y desemboca en rendición de cuentas.

Esa progresión evita que el apartado sea una enumeración y permite leer cada componente como parte de una decisión educativa mayor.

En la gestión de gobernanza institucional de la inteligencia artificial educativa, el enfoque gerencial ayuda a ordenar responsabilidades. Primero se define qué observar; luego se interpreta rol institucional; finalmente se revisa si la acción vinculada con rendición de cuentas tuvo efecto.

La precaución básica en gobernanza institucional de la inteligencia artificial educativa consiste en no confundir señal con explicación suficiente. También existe un riesgo de exceso de confianza. Si el sistema presenta rendición de cuentas como solución

evidente, puede ocultar condiciones que no están en los datos y que solo aparecen mediante dialogo pedagógico.

En gobernanza institucional de la inteligencia artificial educativa, visto así, la idea que queda es prudente: el modelo híbrido ayuda si amplía la comprensión del aprendizaje, no si reemplaza el juicio académico por una clasificación rápida. Con esta base, evaluación de impacto de modelos híbridos inteligentes puede analizarse sin perder la relación entre datos, criterio y acción.

### **5.6. Evaluación de impacto de modelos híbridos inteligentes**

El recorrido no cambia de dirección; se vuelve más específico. Lo trabajado en gobernanza institucional de la inteligencia artificial educativa encuentra aquí, en evaluación de impacto de modelos híbridos inteligentes, una aplicación más concreta.

La pregunta que ordena evaluación de impacto de modelos híbridos inteligentes no es solamente conceptual, sino también institucional y pedagógica. Al operar la modelo universitaria, cada recomendación necesita una razón comprensible. Definir criterios para valorar eficacia, equidad, mejora pedagógica, aceptación y sostenibilidad plantea una pregunta de fondo: que puede hacer mejor la institución cuando comprende el aprendizaje con mayor detalle. La respuesta no está en automatizar la decisión, sino en precisar que información ayuda, que límite tiene y como se traduce en apoyo.

Al analizar evaluación de impacto de modelos híbridos inteligentes, el desarrollo del tema exige observar que los cuatro componentes del apartado cumplen funciones distintas. Eficacia orienta el diagnóstico inicial; Equidad ayuda a reconocer cambios; Aceptación protege la lectura contextual; y Sostenibilidad permite cerrar el circuito con una respuesta formativa.

Al pasar al terreno institucional, evaluación de impacto de modelos híbridos inteligentes deja claro que, en una institución, evaluación de impacto de modelos híbridos inteligentes no puede depender de intuiciones individuales ni de cálculos opacos. Necesita procedimientos claros, registros simples y espacios donde la evidencia se discuta antes de convertirse en decisión.

Evaluación de impacto de modelos híbridos inteligentes pide una verificación constante entre dato, criterio y consecuencia educativa. Una lectura responsable debe reconocer que aceptación puede alterar el significado de cualquier indicador. Dos estudiantes con la misma señal pueden necesitar respuestas distintas.

El argumento avanza así de manera gradual: primero se delimita el problema, luego se precisan los componentes y después se abre el camino hacia prospectiva tecnológica y futuro del aprendizaje personalizado. En la Tabla 18, la lectura operativa queda concentrada en elementos que pueden discutirse antes de intervenir.

**Tabla 18.** Criterios aplicados para evaluación de impacto de modelos híbridos inteligentes.

Criterio de evaluación	Aspecto que permite valorar	Decisión institucional
Eficacia	Grado en que el modelo mejora la detección de necesidades, personalización y los resultados de aprendizaje.	Mantener, ajustar o rediseñar la estrategias según la evidencia obtenida.
Equidad	Impacto del modelo sobre estudiantes con diferentes trayectorias, condiciones de acceso y necesidades de apoyo.	Verificar si la personalización reduce brechas educativas o si requiere correcciones para evitar desigualdades.
Aceptación	Nivel de confianza, comprensión y uso del modelo por parte de estudiantes, docentes y responsables académicos.	Incorporar mejoras en capacitación, comunicación o funcionamiento y cuando la adopción sea limitada.
Sostenibilidad	Capacidad de la institución para mantener el modelo mediante recursos, infraestructura, formación docente y evaluación continua.	Decidir la consolidación, escalabilidad o actualización del modelo como parte de la estrategia institucional.

La síntesis separa el vocabulario técnico de la decisión pedagógica, una distinción necesaria para que el modelo no se limite a clasificar estudiantes. En la evaluación de impacto de modelos híbridos inteligentes, el análisis no debe centrarse únicamente en verificar si el sistema funciona, sino en determinar si sus resultados mejoran de manera efectiva las decisiones educativas, el acompañamiento institucional y las condiciones de aprendizaje.

La eficacia constituye un primer criterio de valoración, pero debe entenderse con cautela. Un modelo puede mostrar buenos resultados en términos de precisión,

predicción o generación de recomendaciones, y aun así tener un impacto limitado si esas recomendaciones no se traducen en mejoras pedagógicas observables.

Por ello, evaluar la eficacia implica revisar si el sistema ayuda a detectar necesidades reales, si permite intervenir a tiempo y si contribuye a mejorar trayectorias, desempeño, participación o permanencia estudiantil.

La equidad amplía esta lectura porque obliga a preguntar si el modelo beneficia a todos los estudiantes o si reproduce diferencias previas. Una herramienta de personalización puede ser técnicamente eficiente, pero injusta si favorece a quienes ya tienen mejores condiciones de acceso, mayor autonomía o trayectorias académicas más estables. Evaluar el impacto exige observar si las recomendaciones llegan a quienes más las necesitan, si los apoyos son pertinentes y si la intervención reduce o amplía brechas educativas.

La aceptación permite incorporar la mirada de los actores que participan en el proceso. Un modelo híbrido inteligente no puede evaluarse solo desde sus resultados técnicos; también debe analizarse desde la experiencia de estudiantes, docentes, tutores, coordinadores y equipos institucionales. Si el sistema es difícil de comprender, si genera desconfianza, si aumenta la carga docente o si sus recomendaciones no son percibidas como útiles, su impacto será limitado.

La sostenibilidad cierra el análisis porque permite valorar si el modelo puede mantenerse en el tiempo. Una experiencia piloto puede mostrar resultados positivos, pero la institución debe preguntarse si cuenta con recursos, formación docente, infraestructura, protocolos, soporte técnico y mecanismos de evaluación continua para sostenerla. Sin sostenibilidad, la personalización inteligente corre el riesgo de convertirse en una innovación temporal, dependiente de esfuerzos aislados y difícil de integrar a la cultura académica.

En este sentido, la evaluación de impacto debe considerar tanto los resultados inmediatos como los efectos institucionales de largo plazo. No basta con medir cuántas alertas se generaron o cuántas recomendaciones fueron entregadas; es necesario revisar qué decisiones se tomaron, quién las validó, qué apoyos se activaron y qué cambios se observaron después de la intervención. La trazabilidad del

proceso permite distinguir entre una personalización aparente y una mejora educativa real.

En evaluación de impacto de modelos híbridos inteligentes, el punto que conviene retener es este: toda personalización debe poder explicarse al estudiante, al docente y a la institución, pero también debe poder evaluarse por sus efectos. Si una recomendación no mejora la comprensión del aprendizaje, no reduce barreras, no fortalece el acompañamiento o no puede sostenerse institucionalmente, su valor educativo queda limitado.

El siguiente tema, prospectiva tecnológica y futuro del aprendizaje personalizado, permite continuar la secuencia y revisar nuevas implicaciones del modelo. Después de analizar cómo valorar eficacia, equidad, aceptación y sostenibilidad, corresponde mirar hacia adelante y preguntarse qué condiciones deberán cumplir las tecnologías educativas para seguir siendo pedagógicamente pertinentes, éticamente responsables e institucionalmente viables.

### **5.7. *Prospectiva tecnológica y futuro del aprendizaje personalizado***

Para mantener el hilo del libro, prospectiva tecnológica y futuro del aprendizaje personalizado debe leerse como continuación de evaluación de impacto de modelos híbridos inteligentes. La diferencia está en el tipo de evidencia y en la responsabilidad que cada decisión activa.

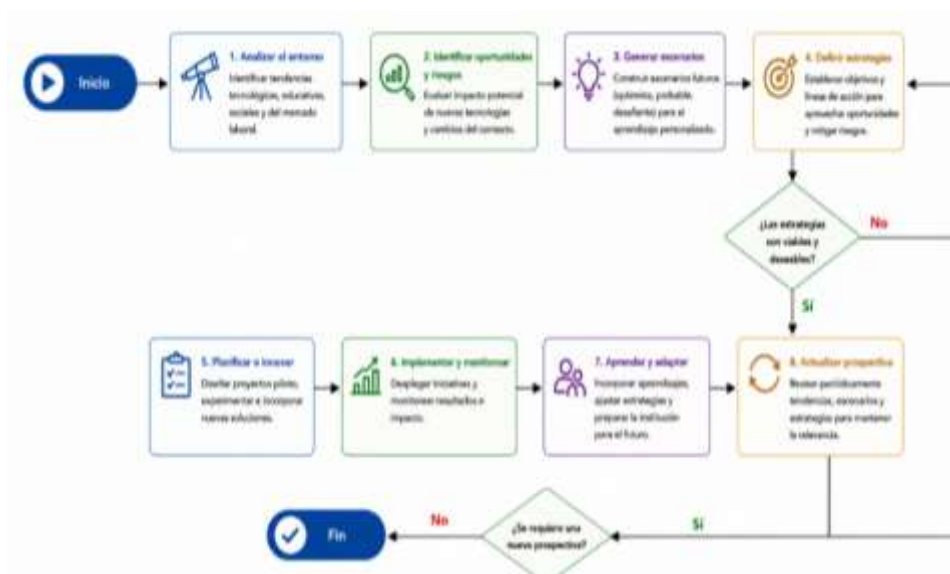
La lectura de prospectiva tecnológica y futuro del aprendizaje personalizado comienza por una pregunta práctica: qué cambia en la intervención educativa. La idea puede parecer sencilla, pero cuando se lleva al aula exige una distinción importante. Explorar tendencias, escenarios, oportunidades y límites de la personalización inteligente en Educación Superior requiere una lectura menos instrumental de la tecnología. Un sistema puede ordenar datos y sugerir rutas, aunque la pertinencia de esas rutas depende de su relación con objetivos, contexto y mediación docente. Esa cautela aparece en la discusión desarrollada por Zawacki-Richter et al. y Tsai y Gašević [8], [26].

El punto delicado en prospectiva tecnológica y futuro del aprendizaje personalizado está en conservar margen para revisar la recomendación del sistema. El problema no

está en usar datos, sino en usarlos sin contexto. Cuando tendencia se interpreta sin mediación, el modelo puede producir decisiones ordenadas, aunque pedagógicamente pobres.

La relación con el tema siguiente es práctica. Si prospectiva tecnológica y futuro del aprendizaje personalizado no se resuelve con claridad, las conclusiones generales de la obra quedasen apoyado sobre supuestos frágiles.

Para que el lector ubique la secuencia completa, la Figura 18 resume el flujo de decisión asociado con el tema.



**Figura 18.** Flujo de decisión para prospectiva tecnológica y futuro del aprendizaje personalizado.

Al analizar prospectiva tecnológica y futuro del aprendizaje personalizado, la exposición se ordena mejor si leídos en conjunto, escenario, tendencia, riesgo y oportunidad forman una cadena de decisión. Primero aparece una señal, luego se interpreta su trayectoria, después se revisa el contexto y finalmente se define una acción que pueda ser observada y corregida.

Cuando el modelo incorpora prospectiva tecnológica y futuro del aprendizaje personalizado, la utilidad del modelo se mide en la coordinación que produce. Cuando docencia, bienestar, tecnología y dirección curricular trabajan con el mismo criterio, escenario deja de ser un dato suelto y se vuelve parte de una estrategia.

En prospectiva tecnológica y futuro del aprendizaje personalizado, el esquema visual debe destacar que prospectiva tecnológica y futuro del aprendizaje personalizado no es una secuencia cerrada. Entre escenario y oportunidad deben aparecer puntos de validación académica, revisión de contexto y ajuste de la intervención.

En prospectiva tecnológica y futuro del aprendizaje personalizado, la consecuencia para el libro es clara: visto en conjunto, prospectiva tecnológica y futuro del aprendizaje personalizado fortalece la obra porque conecta datos, mediación y seguimiento dentro de una misma lógica de responsabilidad. Con este cierre, el manuscrito queda preparado para integrar sus conclusiones y ordenar los conceptos principales.

El recorrido deja una idea central: la personalización inteligente es valiosa cuando mejora decisiones humanas responsables, no cuando las oculta.

## Conclusiones

Los modelos híbridos inteligentes ofrecen una vía sólida para pensar el aprendizaje personalizado en Educación Superior, pero su valor depende de una condición básica: deben mejorar decisiones educativas, no solo producir información. A lo largo del libro, la personalización se ha presentado como un proceso que integra diversidad estudiantil, datos, reglas pedagógicas, modelos predictivos, retroalimentación, acompañamiento y gobernanza.

La primera conclusión es que la tecnología no elimina la complejidad del aprendizaje. La vuelve más visible. Los datos pueden mostrar patrones de participación, desempeño o riesgo, pero no explican por sí solos las condiciones de un estudiante. Por eso, la mediación docente y la interpretación institucional siguen siendo indispensables.

La segunda conclusión es que el carácter híbrido del modelo no es un detalle técnico. Combinar enfoques simbólicos, aprendizaje automático, ontologías, reglas y conocimiento experto permite construir sistemas más comprensibles y ajustables. En educación, esa posibilidad es crucial, porque las decisiones deben responder a fines formativos y no solamente a precisión estadística.

La tercera conclusión se refiere a la ética. Privacidad, transparencia, explicabilidad, sesgos y gobernanza no son anexos del proyecto tecnológico; son condiciones de legitimidad. Una institución que usa modelos inteligentes debe poder explicar que datos recoge, para que los usa, quien interpreta los resultados y como se corrigen errores o impactos no deseados.

En conjunto, el libro propone una idea prudente: la personalización inteligente puede fortalecer la Educación Superior si se integra con diseño pedagógico, cultura institucional y evaluación continua. Su futuro no

---

dependerá solo de modelos más potentes, sino de universidades capaces de usarlos con criterio, responsabilidad y sentido educativo.

### **Contribución y autoría**

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

### **Financiamiento**

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

### **Declaración ética**

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

### **Uso de inteligencia artificial**

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

### **Disponibilidad de datos**

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

### **Conflicto de interés**

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

---

## Referencias

- [1] E. Du Plooy, D. Casteleijn, y D. Franzsen, “Personalized adaptive learning in higher education: A scoping review of key characteristics and impact on academic performance and engagement”, *Heliyon*, vol. 10, núm. 21, p. e39630, nov. 2024, doi: 10.1016/j.heliyon.2024.e39630.
- [2] J. Ning, Z. Ma, J. Yao, Q. Wang, y B. Zhang, “Personalized learning supported by learning analytics: a systematic review of functions, pathways, and educational outcomes”, *Interact. Learn. Environ.*, vol. 33, núm. 8, pp. 5042–5064, sep. 2025, doi: 10.1080/10494820.2025.2478437.
- [3] C. D. Kloos *et al.*, “H2O Learn - Hybrid and Human-Oriented Learning: Trustworthy and Human-Centered Learning Analytics (TaHCLA) for Hybrid Education”, en *2022 IEEE Global Engineering Education Conference (EDUCON)*, Tunis, Tunisia: IEEE, mar. 2022, pp. 94–101. doi: 10.1109/EDUCON52537.2022.9766770.
- [4] B. A. Chaushi, B. Selimi, A. Chaushi, y M. Apostolova, “Explainable Artificial Intelligence in Education: A Comprehensive Review”, en *Explainable Artificial Intelligence*, vol. 1902, L. Longo, Ed., en *Communications in Computer and Information Science*, vol. 1902. , Cham: Springer Nature Switzerland, 2023, pp. 48–71. doi: 10.1007/978-3-031-44067-0\_3.
- [5] I. Yuyun y D. Suherdi, “Components and Strategies for Personalized Learning in Higher Education: A Systematic Review”, en *Proceedings of the 20th AsiaTEFL-68th TEFLIN-5th iNELTAL Conference (ASIATEFL 2022)*, vol. 749, U. Widiati, M. Hidayati, N. Suryati, Suharyadi, A. N. Wulyani, I. L. Damayanti, N. A. Drajadi, S. Karmina, E. L. Zen, L. Hakim, y Prihantoro, Eds., en *Advances in Social Science, Education and Humanities Research*, vol. 749. , Paris: Atlantis Press SARL, 2023, pp. 271–290. doi: 10.2991/978-2-38476-054-1\_23.

- 
- [6] M. A. Chatti y A. Muslim, “The PERLA Framework: Blending Personalization and Learning Analytics”, *Int. Rev. Res. Open Distrib. Learn.*, vol. 20, núm. 1, feb. 2019, doi: 10.19173/irrodl.v20i1.3936.
- [7] W. Villegas-Ch y J. García-Ortiz, “Enhancing Learning Personalization in Educational Environments through Ontology-Based Knowledge Representation”, *Computers*, vol. 12, núm. 10, p. 199, oct. 2023, doi: 10.3390/computers12100199.
- [8] O. Zawacki-Richter, V. I. Marín, M. Bond, y F. Gouverneur, “Systematic review of research on artificial intelligence applications in higher education – where are the educators?”, *Int. J. Educ. Technol. High. Educ.*, vol. 16, núm. 1, p. 39, dic. 2019, doi: 10.1186/s41239-019-0171-0.
- [9] C. Guzmán-Valenzuela, C. Gómez-González, A. Rojas-Murphy Tagle, y A. Lorca-Vyhmeister, “Learning analytics in higher education: a preponderance of analytics but very little learning?”, *Int. J. Educ. Technol. High. Educ.*, vol. 18, núm. 1, p. 23, dic. 2021, doi: 10.1186/s41239-021-00258-x.
- [10] M. Blumenstein, “Synergies of Learning Analytics and Learning Design: A Systematic Review of Student Outcomes”, *J. Learn. Anal.*, vol. 7, núm. 3, pp. 13–32, dic. 2020, doi: 10.18608/jla.2020.73.3.
- [11] J. Liang *et al.*, “Student Modeling and Analysis in Adaptive Instructional Systems”, *IEEE Access*, vol. 10, pp. 59359–59372, 2022, doi: 10.1109/ACCESS.2022.3178744.
- [12] S. Lonn y B. Koester, “Rearchitecting Data for Researchers: A Collaborative Model for Enabling Institutional Learning Analytics in Higher Education”, *J. Learn. Anal.*, vol. 6, núm. 2, jul. 2019, doi: 10.18608/jla.2019.62.8.
- [13] J. Peng y Y. Li, “Frontiers of Artificial Intelligence for Personalized Learning in Higher Education: A Systematic Review of Leading


- Articles”, *Appl. Sci.*, vol. 15, núm. 18, p. 10096, sep. 2025, doi: 10.3390/app151810096.
- [14] H. Khosravi, K. Kitto, y J. J. Williams, “RiPPLE: A Crowdsourced Adaptive Platform for Recommendation of Learning Activities”, *J. Learn. Anal.*, vol. 6, núm. 3, dic. 2019, doi: 10.18608/jla.2019.63.12.
- [15] R. J. Waddington, S. Nam, S. Lonn, y S. D. Teasley, “Improving Early Warning Systems with Categorized Course Resource Usage”, *J. Learn. Anal.*, vol. 3, núm. 3, pp. 263–290, dic. 2016, doi: 10.18608/jla.2016.33.13.
- [16] G. Ramaswami, T. Susnjak, y A. Mathrani, “Effectiveness of a Learning Analytics Dashboard for Increasing Student Engagement Levels”, *J. Learn. Anal.*, vol. 10, núm. 3, pp. 115–134, dic. 2023, doi: 10.18608/jla.2023.7935.
- [17] K. Bayly-Castaneda, M.-S. Ramirez-Montoya, y A. Morita-Alexander, “Crafting personalized learning paths with AI for lifelong learning: a systematic literature review”, *Front. Educ.*, vol. 9, p. 1424386, ago. 2024, doi: 10.3389/educ.2024.1424386.
- [18] R. Hidalgo y G. Evans, “Analytics for Action: Assessing effectiveness and impact of data informed interventions on online modules”, *RIED Rev. Iberoam. Educ. Distancia*, vol. 23, núm. 2, p. 103, jul. 2020, doi: 10.5944/ried.23.2.26450.
- [19] D. Ifenthaler, D. Gibson, y E. Dobozy, “The synergistic and dynamic relationship between learning design and learning analytics”, *ASCILITE Publ.*, pp. 112–116, nov. 2017, doi: 10.14742/apubs.2017.752.
- [20] E. T. Khor y M. K, “A Systematic Review of the Role of Learning Analytics in Supporting Personalized Learning”, *Educ. Sci.*, vol. 14, núm. 1, p. 51, dic. 2023, doi: 10.3390/educsci14010051.
- [21] F. Jin, B. Maheshi, R. Martinez-Maldonado, D. Gašević, y Y.-S. Tsai, “Scaffolding Feedback Literacy: Designing a Feedback Analytics Tool

- 
- with Students”, *J. Learn. Anal.*, vol. 11, núm. 2, pp. 123–137, jul. 2024, doi: 10.18608/jla.2024.8339.
- [22] D. Ifenthaler y J. Y.-K. Yau, “Utilising learning analytics to support study success in higher education: a systematic review”, *Educ. Technol. Res. Dev.*, vol. 68, núm. 4, pp. 1961–1990, ago. 2020, doi: 10.1007/s11423-020-09788-z.
- [23] Z. Pan, L. Biegley, A. Taylor, y H. Zheng, “A Systematic Review of Learning Analytics: Incorporated Instructional Interventions on Learning Management Systems”, *J. Learn. Anal.*, vol. 11, núm. 2, pp. 52–72, may 2024, doi: 10.18608/jla.2023.8093.
- [24] N. Bergdahl, M. Bond, J. Sjöberg, M. Dougherty, y E. Oxley, “Unpacking student engagement in higher education learning analytics: a systematic review”, *Int. J. Educ. Technol. High. Educ.*, vol. 21, núm. 1, p. 63, dic. 2024, doi: 10.1186/s41239-024-00493-y.
- [25] A. N. Cormack, “A Data Protection Framework for Learning Analytics”, *J. Learn. Anal.*, vol. 3, núm. 1, abr. 2016, doi: 10.18608/jla.2016.31.6.
- [26] I. Rets, C. Herodotou, y A. Gillespie, “Six Practical Recommendations Enabling Ethical Use of Predictive Learning Analytics in Distance Education”, *J. Learn. Anal.*, vol. 10, núm. 1, pp. 149–167, feb. 2023, doi: 10.18608/jla.2023.7743.
- [27] J. Weidlich, D. Gašević, y H. Drachsler, “Causal Inference and Bias in Learning Analytics: A Primer on Pitfalls Using Directed Acyclic Graphs”, *J. Learn. Anal.*, vol. 9, núm. 3, pp. 183–199, dic. 2022, doi: 10.18608/jla.2022.7577.
- [28] N. Elouazizi, “Critical Factors In Data Governance For Learning Analytics”, *J. Learn. Anal.*, vol. 1, núm. 3, pp. 211–222, ago. 2014, doi: 10.18608/jla.2014.13.25.

- 
- [29] N. Sclater, “Developing a Code of Practice for Learning Analytics”, *J. Learn. Anal.*, vol. 3, núm. 1, abr. 2016, doi: 10.18608/jla.2016.31.3.
- [30] Y.-S. Tsai y D. Gasevic, “Learning analytics in higher education --- challenges and policies: a review of eight learning analytics policies”, en *Proceedings of the Seventh International Learning Analytics & Knowledge Conference*, Vancouver British Columbia Canada: ACM, mar. 2017, pp. 233–242. doi: 10.1145/3027385.3027400.

#### **Descargo de responsabilidad**

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



EDITORIAL  
**UNIÓN CIENTÍFICA**